

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Filip Faletar

RAZVOJ SOFTVERSKJE PODRŠKE ZA AHP
METODU

DIPLOMSKI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Filip Faletar

Matični broj: 45279/16–R

Studij: Informacijsko i programsko inženjerstvo

RAZVOJ SOFTVERSKJE PODRŠKE ZA AHP
METODU

DIPLOMSKI RAD

Mentor/Mentorica:

Izv. prof. dr. sc. Nina Begičević Ređep

Varaždin, rujan 2018.

Filip Faletar

Izjava o izvornosti

Izjavljujem da je moj završni/diplomski rad izvorni rezultat mog rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor/Autorica potvrdio/potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Glavni fokus ovog diplomskog rada je razvoj softverske podrške za AHP metodu koja je jedna od najviše korištenih metoda za višekriterijsko odlučivanje. U teorijskom dijelu AHP metoda je predstavljena preko svojih koraka, matematičke osnove te aksioma na kojima se temelji, uz odgovarajuće demonstracijske primjere. U praktičnom dijelu, razvijena je softverska podrška za metodu AHP. Softversko rješenje je web aplikacija koja omogućava unos hijerarhijskog stabla odlučivanja, uspoređivanje u parovima, izračun težina kriterija, lokalnih i globalnih prioriteta alternativa, izračun indeksa nekonzistentnosti, različite vrste analiza osjetljivosti te izradu izvještaja. Posebnosti ove aplikacije u odnosu na druge aplikacije za podršku AHP metodi su: (1) unos matrice odlučivanja, tj. stvarnih vrijednosti alternativa po kriterijima koje se pojavljuju u postupku uspoređivanja u parovima čime se donositelj odluka bolje fokusira na sadržaj usporedbe; (2) nešto drugačije analize osjetljivosti (utjecaj promjene veličine pojedinih usporedbi u parovima na prioritete, dinamička analiza osjetljivosti cijele hijerarhije); te (3) izrada personaliziranog izvještaja kod kojeg donositelj odluke bira što će biti u izvještaju pri čemu u analizi osjetljivosti može spremati grafove analize osjetljivosti za željene situacije te ih kombinirati u konačni izvještaj.

Ključne riječi: odlučivanje, analitički hijerarhijski proces, AHP, softverska podrška, sustav za podršku odlučivanju, DSS

Sadržaj

1.	Uvod.....	1
2.	Sustavi za potporu odlučivanju	3
3.	AHP metoda	5
3.1.	Višekriterijsko odlučivanje.....	5
3.2.	Uvod u metodu AHP	6
3.3.	Koraci provedbe metode AHP	8
3.3.1.	Definiranje problema i cilja – razvoj hijerarhijskog modela	9
3.3.2.	Uspoređivanje u parovima	10
3.3.3.	Izračun lokalnih i globalnih prioriteta hijerarhijske strukture te provjera konzistentnosti	11
3.3.4.	Provođenje analize osjetljivosti	12
3.3.5.	Izbor alternative	12
3.4.	Konzistentnost uspoređivanja u metodi AHP	12
3.5.	Aksiomi na kojima se temelji metoda AHP	15
3.5.1.	Aksiom recipročnosti.....	15
3.5.2.	Aksiom hijerarhije.....	16
3.5.3.	Aksiom homogenosti.....	16
3.5.4.	Aksiom očekivanja	16
3.6.	Grupno odlučivanje AHP metodom	17
4.	Razvoj softvera	18
4.1.	Opis postojećeg stanja	18
4.2.	Korišteni alati, tehnologije i programski jezici	19
4.3.	Funkcionalnosti.....	19
4.4.	Osnove razvoja softvera	21
4.5.	Mogućnosti proširenja.....	25
4.6.	Pregled softverskih funkcionalnost.....	26
5.	Demonstracija korištenja softver	46
5.1.	Strukturiranje problema	46
5.2.	Uspoređivanje u parovima	50
5.3.	Sinteza rezultata	53
5.4.	Analiza osjetljivosti dobivenih rezultata	56
5.4.1.	Analiza osjetljivosti konačnog ishoda na promjenu intenziteta važnosti pojedine usporedbe	56
5.4.2.	Analiza osjetljivosti performansi	57

5.4.3.	Dinamička analiza osjetljivosti	58
5.4.4.	Analiza osjetljivosti odnosa	60
6.	Zaključak	61
7.	Popis literature.....	62
8.	Popis slika	64
9.	Popis tablica	66
10.	Prilozi.....	67

1. Uvod

Donošenje odluka je proces s kojim se svakodnevno susrećemo, nekad i neprimjetno. Bilo da se radi o privatnom ili poslovnom životu, iza nas je mnogo donesenih odluka, no još je više onih s kojima ćemo se tek trebati donijeti. Donesena odluka može rezultirati dobrim ili lošim ishodom. U nekim situacijama su takve odluke dugoročno važne, no postoje i odluke koje ne znače mnogo i kratkoročne su. Naravno, kod svakog donošenja odluke, najbitniji je krajnji ishod koji predstavlja bolju ili lošiju situaciju. Iako toga nismo u potpunosti svjesni, možemo zaključiti da je donošenje odluka vrlo bitan faktor naše svakodnevnice.

U svijetu poslovanja je puno jasnija priča. Gotovo svaka veća odluka je izuzetno značajna za daljnji tijek poslovnih procesa, stoga je vrlo bitno pravovremeno donijeti ispravne i upotrebljive odluke. Kroz svaki poslovni proces unutar neke tvrtke, provlači se i proces donošenja odluka. Zsigurno, glavni cilj tvrtke je ostvariti najveći mogući profit u određenom vremenskom razdoblju. Za konstantno ostvarivanje najvećeg mogućeg profita, tvrtka mora biti dobro organizirana, te mora efikasno i efektivno obavljati djelatnosti za koje je zadužena. Ukoliko to ne radi, konkurentnost postaje najveći problem takve tvrtke. Bilo da se radi o tržištu ili o poslovnim procesima unutar tvrtke, svakako će se često pojavljivati potreba za donošenjem odluka. Izbjegavanje uviđanja potrebe za donošenjem odluka te razumijevanje važnosti istih, karakteristike su one tvrtke koja će se uvijek razlikovati od tvrtke koja ostvaruje najbolje rezultate na tržištu. Stoga, proces donošenja odluka uvijek mora biti jedan od važnijih procesa unutar svake tvrtke. Današnja tržišta sklona su velikim promjenama koje brzo nastupaju, pa je nakon svake takve promjene potrebno žurno i pravilno reagirati pokretanjem procesa donošenja odluka. U odnosu na one manje, veće tvrtke imaju veću i češću potrebu za donošenjem odluka.

Potpune i pravodobne informacije bitna su vrlo stavka svakog donošenja odluka. Tako, precizne i pravodobno dobivene informacije čine neophodan resurs pri donošenju odluka. Donošenje odluka je moguće kada postoje minimalno dvije alternative koje rješavanju određeni problem ili poteškoću. Jasno je, da postoji samo jedna alternativa prilikom rješavanja nekog problema, ne bi postojala potreba za donošenjem odluke. Dakle, donošenje odluka je pristup rješavanju određenog problema ili poteškoće izborom određene alternative iz nekog skupa alternativa.

O donošenju odluka ovisi osobni uspjeh, kao i uspjeh tima i/ili tvrtke. Važno je napomenuti da je svako donošenje odluka, bilo da se radi o dobroj ili lošoj odluci, temelj za buduće donošenje odluka. Zašto? Jer od svake dobre ili loše odluke možemo nešto naučiti i to je ono što današnje menadžere čini pravim osobama za planiranje, organiziranje,

upravljanje i koordinaciju poslovanja tvrtke. Naravno, uvijek će postojati neispravne odluke, no pitanje je u kojim količinama. Da bi se one smanjile, tvrtke počinju koristiti računalne programe koji usmjeravaju donositelja odluke k izboru prave alternative.

Sustavi za potporu odlučivanju (engl. *Decision Support Systems* - DSS) su stvoreni kako bi donositeljima odluka olakšalo donošenje kompleksnih i vrijednih odluka. Kvaliteta kompleksnih odluka u mnogo je situacija presudna za budućnost tvrtke, stoga bi se ljudska intuicija morala izbjegavati u istima. U suprotnom, iz toga proizlaze rezultati koji su daleko od onih optimalnih. Takvi rezultati se moraju izbjegavati jer donose neželjene posljedice, odnosno neuspjeh na tržištu.

Bez donošenja odluka, bilo koja funkcija tvrtke nije moguća. Donošenje odluka proteže se kroz sve sektore svake tvrtke, stoga se pojavljuje potreba za kvalitetnijim i preciznijim sustavima za donošenje odluka, no samim time, i za novim metodama za donošenje odluka.

U ovom radu biti će definirani sustavi za potporu odlučivanju te AHP metoda. Zatim će biti navedeni svi koraci razvoja sustava za potporu odlučivanju korištenjem navedene metode, a potom i pojašnjenje gotovog sustava uz primjer korištenja.

2. Sustavi za potporu odlučivanju

Poslovne odluke izuzetno su bitne, kako u procesu stvaranja poslovanja, tako i u procesu održavanja i unaprjeđivanja istog. Ispravno i pravovremeno donošenje odluka je aspekt poslovanja koji čini razliku među tvrtkama na istom tržištu. No, koji dio donošenja odluka čini razliku? Jesu li to pojedinci koji ispravno i pravovremeno odlučuju ili su to ipak sustavi koji daju podršku u odlučivanju. „Poslovno odlučivanje je izbor između dvije ili više inačica rješavanja problema, ali u poslovnim situacijama“. [1].

Prethodno smo zaključili da je poslovno odlučivanje jedan od važnijih aspekata organizacije, u borbi s vlastitom egzistencijom. No, sasvim je normalno da su menadžeri skloni greškama, pa tako i greškama pri donošenju važnih odluka. Kao što je već navedeno, današnje tržište je veoma promjenjivo, stoga je izuzetno teško ostati konkurentan. Da bi se olakšalo donošenje ispravnih odluka, pojavljuju se sustavi za potporu odlučivanju. Takvi sustavi pomažu menadžerima pri donošenju kompleksnih i važnih odluka. Menadžeri u samom procesu odlučivanja dolaze do niza problema, pojavljuje se spoznajno, vremensko i ekonomsko ograničenje. Spoznajno ograničenje odnosi se na nedostatak točnih, pravodobnih i cjelovitih informacija, vremensko ograničenje na nedovoljno vrijeme potrebno za analizu informacija i rješavanja problema, dok se ekonomsko ograničenje odnosi na nemogućnost podnošenja nastalih troškova pri procesu odlučivanja [1].

Zbog navedenih problema pojavljuju se sustavi za potporu odlučivanju. Oni služe za rješavanje nestrukturiranih i strukturiranih problema. Danas je poznato mnoštvo sustava za potporu odlučivanju, koji se koriste raznim tehnikama i sredstvima kako bi pomogli donositelju odluka ispuniti cilj. Uz sustave za potporu odlučivanju (engl. DSS – *Decision support systems*), postoje i upravljački informacijski sustavi (engl. MIS – *Management information systems*), ekspertni sustavi (engl. ES – *Expert systems*), sustavi za obradu transakcija (engl. TPS – *Transaction processing systems*), sustavi za potporu vrhovnom rukovodstvu (engl. ESS – *Executive support systems*), sustavi za podršku grupnom odlučivanju (engl. GDSS – *Group decision support systems*) i sustavi za automatizaciju ureda (engl. OAS – *Office automation systems*).

Sustavi za obradu transakcija izvršavaju procese vođenja evidencije, prikupljana informacija i izvještavanja. „Sustavi za obradu transakcija ne omogućuju izravnu potporu odlučivanju, ali osiguravaju evidenciju o osnovnim aktivnostima i transakcijama organizacije, pružaju potporu tekućem zbivanju poslovnih procesa u organizaciji, podupiru procesiranje poslovnih operacija te generiraju dokumente potrebne u poslovanju“ [1]. Za razliku od sustava za obradu transakcija, upravljački informacijski sustavi ipak na neki način sudjeluju u

odlučivanju. Takav sustav ulazne podatke prima iz sustava za obradu transakcija te efikasno pruža informacije za generiranje izvještaja, modela i analiza potrebnih za donošenje odluka. Sustavi za potporu grupnom odlučivanju, kao što i sam naziv predočava, je proširenje sustava za potporu odlučivanju. Iako imaju jednaku ulogu i funkcioniraju na isti način, sustavi za potporu odlučivanju ipak olakšavaju kompleksnije donošenje odluka, te omogućava preciznije donošenje istih. Tako pomoću navedenog sustava grupa menadžera može istovremeno pojedinačno odlučivati, a potom se njihovi rezultati komprimiraju u jedan konačni rezultat. Ekspertni sustavi spadaju pod područje umjetne inteligencije. Ekspertni sustavi su računalni programi koji koriste znanje za rješavanje praktičnih problema za koje je inače potrebna ljudska ekspertiza [2].

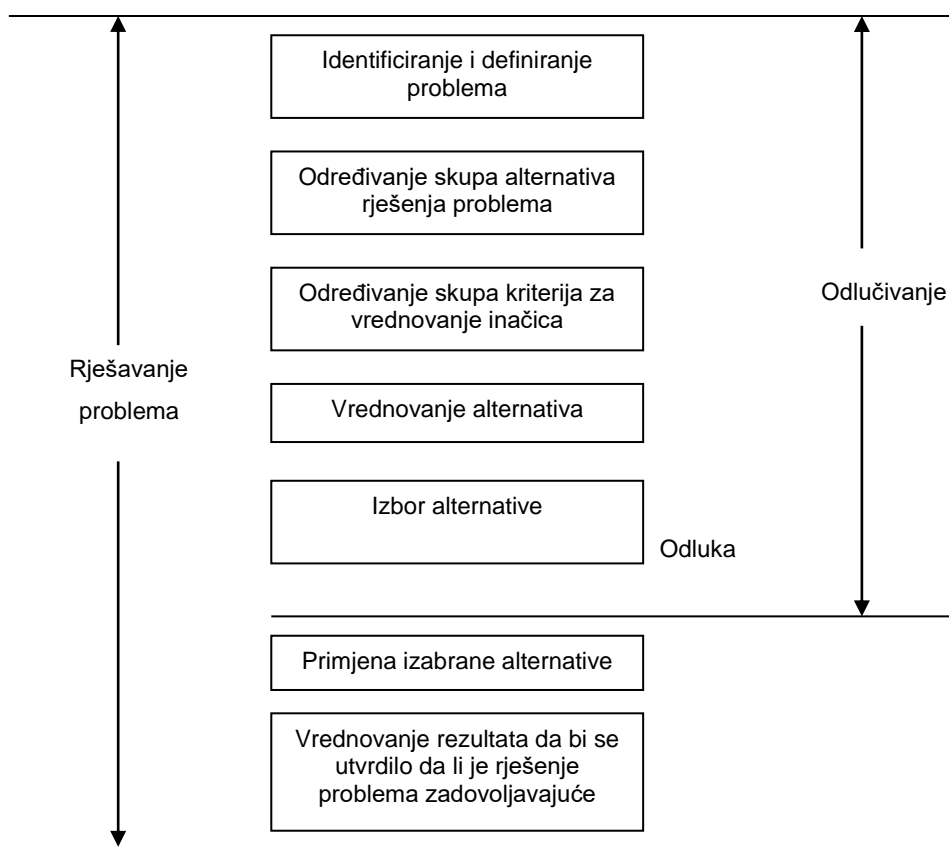
No, vratimo se na ono važno, sustave za potporu odlučivanju (DSS). Potrebe za takvim sustavima postoji odavno, a svakim danom je sve veća. Zato su se takvi sustavi pojavili još u ranim 70-im godinama prošlog stoljeća, a danas ih je mnoštvo.

Mnogo problema današnjih organizacija svodi se na nedostatak informacijske potpore, što u puno slučajeva rukovodstvo ne zna prepoznati. Konkurentnost, ukupni profit i stalni rast rezultat su dobre informacijske potpore. Stoga se svakim danom sve više koriste navedeni sustavi. Naravno, navedeni sustavi neće zamijeniti donositelja odluke, nego će samo olakšati njegov zadatak. Dakle, glavni cilj ovih sustava je pružanje pravodobnih i točnih informacija donositelju odluke, koji tada može obaviti svoj dio zadatka.

3. AHP metoda

3.1. Višekriterijsko odlučivanje

Odlučivanje je izbor između više alternativa pri čemu nastojimo da to bude što bolji izbor. Odlučivanjem često rješavamo neki problem birajući između više alternativa koje nam stoje na raspolaganju. Vrlo često, na početku rješavanja problema definiramo glavni cilj koji želimo postići rješavanjem problema. Cilj možemo dekomponirati na podciljeve koje želimo zadovoljiti. Npr. ako je problem *nemogućnost brze komunikacije*, za koji je definiran cilj *nabava mobitela*, vrlo često ćemo osim glavnog cilja, barem intuitivno definirati i neke druge podciljeve: *želimo mobitel koji nije skup, koji je kvalitetan (dobra marka), da mu baterija traje što duže, da ima određenu (ili što veću) veličinu ekrana, da ima što jači procesor i što više radne memorije*. Svaki od navedenih ciljeva opisujemo jednim ili više kriterija pa kako imamo više ciljeva, imamo i više kriterija te stoga logično govorimo o višekriterijskom odlučivanju. Prilikom višekriterijskog odlučivanja slijedimo korake prikazane na Slici 1.



Slika 1 Odnos između rješavanja problema i odlučivanja (prilagođeno prema [1])

Kriterije dijelimo na dvije osnovne vrste: kvalitativni i kvantitativni kriteriji. Postoji i podjela na tipove kriterija: *min* kriteriji (kriteriji troška) i *max* kriteriji (kriteriji koristi).

Velik je broj metoda koje se koriste u višekriterijskom odlučivanju: metoda AHP (Analitički Hijerarhijski Proces), metoda ANP (Analitički Mrežni (engl. *Network*) Proces), Elektra, Prometej, Metoda ekvivalentnih zamjena, Topsis, VIKOR (Višekriterijumska optimizacija i KOmpromisno Rešenje), metoda DEX (*Decision EXpert*). U ovom radu bavimo se metodom AHP.

Probleme višekriterijskog odlučivanja opisujemo tablicom odlučivanja (Tablica 1).

Tablica 1. Opći prikaz tablice odlučivanja [1]

	$f_1(\cdot)$	$f_2(\cdot)$...	$f_j(\cdot)$...	$f_k(\cdot)$
	w_1	w_2	...	w_j	...	w_k
a_1	$f_1(a_1)$	$f_2(a_1)$...	$f_j(a_1)$...	$f_k(a_1)$
a_2	$f_1(a_2)$	$f_2(a_2)$...	$f_j(a_2)$...	$f_k(a_2)$
...
a_i	$f_1(a_i)$	$f_2(a_i)$...	$f_j(a_i)$...	$f_k(a_i)$
...
a_n	$f_1(a_n)$	$f_2(a_n)$...	$f_j(a_n)$...	$f_k(a_n)$

Metode višekriterijskog odlučivanja imaju primjenu u širokom spektru grana znanosti i industrije poput ulaganja u projekte, upravljanju objektima, utjecaju na okoliš, odabiru najpogodnijih lokacija, odabiru najpovoljnijeg prostornog rasporeda proizvodnog sustava, odabiru najpovoljnijeg prometnog pravca, internet bankarstvu, odabiru dobavljača, odabiru strategije održavanja i slično

3.2. Uvod u metodu AHP

Analitički hijerarhijski proces (engl. *AHP - Analytic Hierarchy Process*) je strukturirana matematička tehnika koja olakšava proces donošenja odluka. U zadnjih nekoliko godina izuzetno je popularan među menadžerima unutar većih organizacija, no ubrzano se širi i na ostale sektore poslovanja. Trenutačno spada u najkorištenije metode za višekriterijsko odlučivanje. Bitno je napomenuti da AHP metoda ne može samostalno odlučivati, već na temelju preferencija menadžera/donositelja odluke, procjenjuje kriterije prema njihovoj

važnosti i prema navedenim procjenama generira izvješća koja menadžeru daju uvid u najoptimalnije alternative. Iako AHP metoda generira konačni poredak unesenih alternativa, nije nužno da se organizacija orijentira prema toj odluci.

AHP metoda je razvijena od strane Thomasa Saaty-a u sedamdesetim godina prošloga stoljeća. Metoda se zasniva na uspoređivanju u parovima, kako kriterija, tako i alternativa. S obzirom da se konačno rješenje dobiveno AHP metodom uglavnom očituje kroz korisničke preferencije, moguća su i veća odstupanja od idealnog rješenja. No, ipak, takva odstupanja ovise o menadžerskim kvalitetama. Dakle, AHP metoda prepoznaje problem i cilj, te strukturira dobivene informacije u cjelinu koja pomaže pri donošenju odluka. Pod cjelinom smatramo razne strukturirane izlazne podatke, kao što su grafovi koji pružaju bolji uvid u realnu situaciju.

Navedena metoda smatra se metodom višekriterijskog odlučivanja jer se temelji na prvotnom definiranju kriterija koji se kasnije uspoređuju u parovima. Vrednovanje kriterija omogućuje raspoznavanje kriterija prema njihovoj važnosti. Elementi AHP metode su cilj, kriteriji, podkriteriji i alternative, gdje svi navedeni elementi predstavljaju ulazne vrijednosti.

Svoju popularnost ova metoda u velikoj mjeri zahvaljuje tome što je hijerarhijski model složenog problema odlučivanja, koji se koristi u njoj, blizak načinu na koji ljudi intuitivno analiziraju složene probleme razlažući ih na jednostavnije aspekte. Osobito se primjenjuje u donošenju odluka u grupi odnosno u situacijama kada pojedinci kolektivno donose odluku za jednu od alternativa ispred njih samih. Odluka se tada ne može pripisati jednom pojedincu koji je član grupe zato što svi pojedinci pridonose ishodu. AHP pretvara te procjene na numeričke vrijednosti koje se dalje mogu obrađivati i uspoređivati u cijelom rasponu problema.

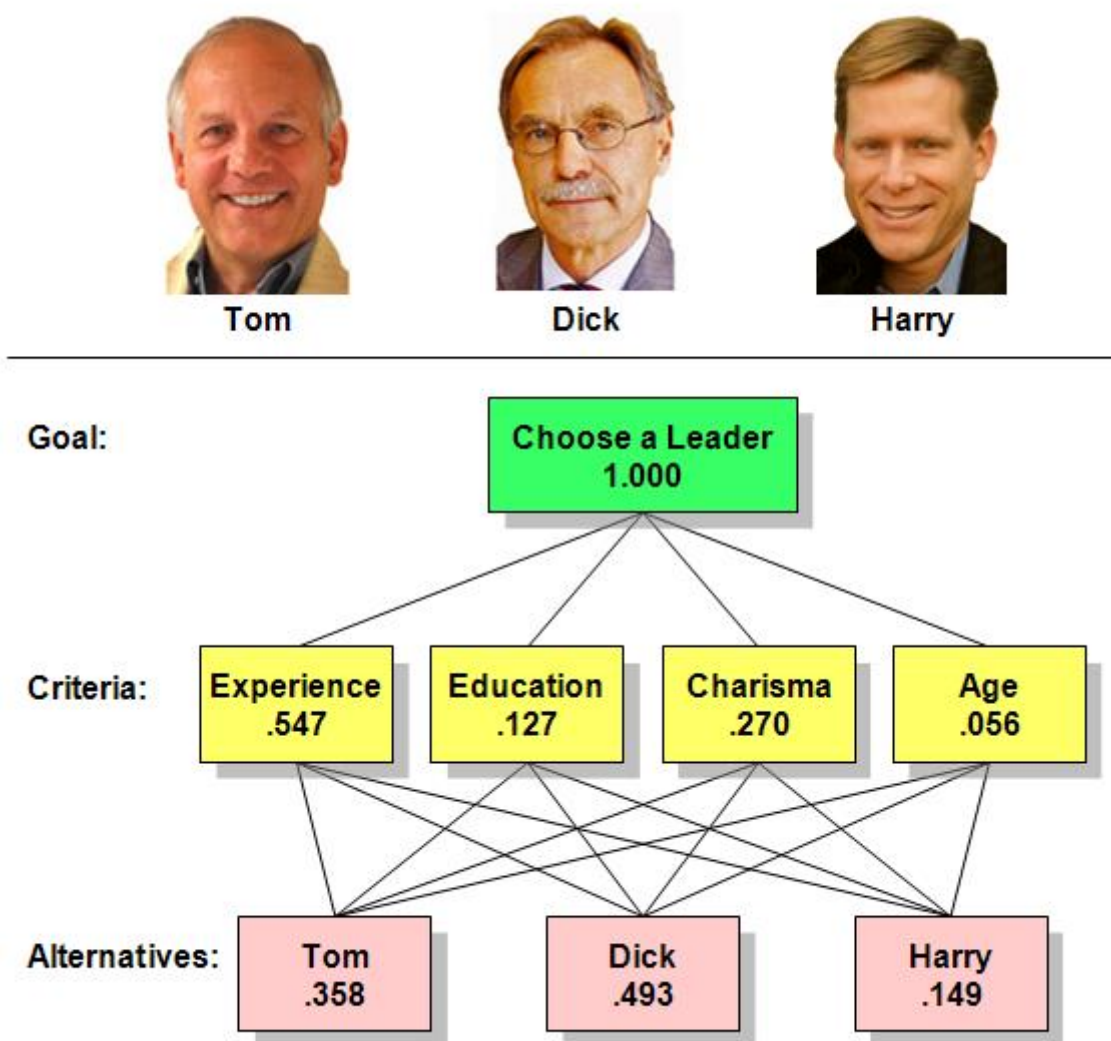
Na primjeru Slike 2. je vidljiva jednostavna hijerarhija koja se sastoji od nužnih elemenata za provođenje AHP metode, cilj, kriteriji i alternative. Također, prikazane su relativne važnosti svakog kriterija i izračunate relativne važnosti alternativa prema navedenim kriterijima. Dakle, u ovom primjeru, cilj je odabrati novog voditelja organizacije, a odlučeno je da su kriteriji po kojima će se odlučivati sljedeći:

- Radno iskustvo (engl. *Experience*)
- Edukacija (engl. *Education*)
- Karizma (engl. *Charisma*)
- Godine (engl. *Age*)

Vidljivo je da su provođenjem AHP metode definirane relativne važnosti navedenih kriterija. Možemo prepoznati jako visoku relativnu važnosti kriterija „Radno iskustvo“, a potom slijede karizma, edukacija i godine, kao kriterij s najmanjom relativnom važnošću. Što

znači da će donositelji odluke najveću prednost davati natjecateljima koji imaju više iskustva. Izlazni podatak AHP metode su relativne važnosti alternativa u odnosu na kriterije.

AHP: Choosing a Leader



Slika 2 Primjer hijerarhijskog modela ([3]–[5])

3.3. Koraci provedbe metode AHP

AHP metoda ima široku primjenu u rješavanju različitih vrsta problema. Ona omogućuje korisnicima da dekompozicijom složenog problema strukturiraju ulazne elemente u hijerarhijsku strukturu te pomoću poznatih aksioma konačno dobiju relativne važnosti alternativa. Primjena AHP metode očituje se kroz nekoliko koraka objašnjenih u nastavku [3].

Četiri su osnovna koraka u provedbi metode AHP [4], [5]:

1. Razvoj hijerarhijskog modela odlučivanja s ciljem na vrhu hijerarhije, kriterijima na idućim razinama te alternativama na zadnjoj razini hijerarhije,
2. Uspoređivanje elemenata iste razine zavisnih od istog elementa u parovima,
3. Izračun prioriteta elemenata (težina kriterija, lokalnih i globalnih prioriteta alternativa),
4. Provođenje analize osjetljivosti.

3.3.1. Definiranje problema i cilja – razvoj hijerarhijskog modela

Naravno, cijeli proces započinje jasnim definiranjem problema i cilja. Potrebno je detaljno razjasniti problem koji se pojavio, objektivno definirati cilj koji se želi postići AHP metodom. Poželjno je približno definirati elemente koji će se koristiti tijekom cijelog procesa.

AHP metoda pruža značajno razvijen i siguran okvir za strukturiranje problema i definiranje elemenata koji čine problem. Kroz proces se koriste različite tehnike koje sažimaju problem i navedene elemente u cjelinu, s ciljem postizanja konačnog rješenja problema [6]. Također, potrebno je i definirati vanjske elemente koji utječu na konačnu odluku. Primjerice, ukoliko jedan član, iz grupe donositelja odluke, nije u mogućnosti racionalno procijeniti intenzitete važnosti kriterija, tada taj član ne bi trebao sudjelovati u donošenju odluke. Pod hijerarhijskim modelom misli se na skup kriterija razvrstanih po razinama unutar hijerarhije, gdje se na istoj razini nalaze kriteriji koji su međusobno usporedivi. Također, svaki kriterij unutar navedenog stabla može imati maksimalno jednog roditelja. S obzirom da smo prethodno definirali problem, taj problem je moguće razgranati na nekoliko manjih problema. Potom je iz navedenih problema moguće definirati kriterije koji će utjecati na konačnu odluku koja rješava glavni problem. Za početak je potrebno definirati vrhovne kriterije koji su važni za konačnu odluku, a zatim se ti kriteriji granaju na više podkriterija. Primjerice, ako postoji kriterij „Prostranost automobila“ tada se taj kriterij može podijeliti na dva podkriterija „Prostranost unutrašnjosti“ i „Prostranost bunkera“. Ako neki kriterij ili podkriterij poprimi procijenjenu relativnu vrijednost u iznosu od 3% ili manje, tada bi se trebalo razmotriti eliminiranje tog kriterija iz hijerarhijskog stabla [5]. Također, Thomas Saaty navodi da je poželjno dodati kriterije u vidu prednosti, mogućnosti, troškova i rizika odluke koje ćemo donijeti. Odnosno, procjenjujemo koji kriteriji bi najviše utjecali na trošak ili koji bi kriteriji najviše utjecali na povećanje rizika. Također, pitamo se što će najviše utjecati na povećanje ili smanjenje prednosti, i koji kriteriji bi mogli povećati mogućnosti kod zadanog problema [7].

Posljednji korak, prije procesa usporedbe i izračuna, je definiranje alternativa. Poželjno je precizno definiranje mogućih alternativa, a isto tako i precizno definiranje njezinih karakteristika. Alternative predstavljaju karakteristike subjekta kojeg se procjenjuje. Procjena se vrši da bi se bolje razumjele percepcije korisnika.

Prije početka izračuna, za svaku alternativu, u odnosu na neki kriterij, potrebno je što detaljnije objasniti njezine karakteristike. Navedene karakteristike pomažu prilikom procjenjivanja intenziteta važnosti alternative u usporedbi s drugom alternativom. Što znači da je, ukoliko je cilj odabirati mobilni telefon, poželjno dodati stvarne informacije o internoj memoriji, kameri itd. Da bi procjena bila valjanja, potrebno je dodati relevantne podatke koji detaljno opisuju pojedinu alternativu. Nakon ovog koraka, opsežna lista alternativa mora biti pripremljena kako bi se moglo nastaviti s ostalim AHP procesima [7].

Kod strukturiranja problema odlučivanja mogu se koristiti [6]:

- Intervjui s ekspertima u problemskoj domeni,
- Pregled literature (traženje sličnih problema odlučivanja koji su ranije riješeni),
- *Brainstorming* i tehnike kreativnosti – kreiranje novih alternativa (ako nisu poznate),
- Delphi metoda – usuglašavanje popisa kriterija i formiranje hijerarhije,
- *Top-down* pristup – dekompozicija kriterija u hijerarhiji,
- *Bottom-up* pristup, metode klasteriranja - grupiranje kriterija u hijerarhiji,
- ProACT pristup u raščlambi problema odlučivanja.

3.3.2. Uspoređivanje u parovima

Središnji korak metode AHP predstavlja uspoređivanje u parovima. Prilikom uspoređivanja u parovima koristi se Saatyjeva skala relativnih važnosti.

Tabela 2 Saatyjeva skala - temeljna skala apsolutnih brojeva [8], [9]

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednako važan	Koristi se kada oba faktora jednako djeluju na konačan rezultat
3	Donekle važniji	Koristi se kada je mala razlika na strani jednog faktora u odnosu na drugi
5	Mnogo važniji	Koristi se kada je jedan faktor mnogo važniji od drugog faktora
7	Znatno važniji	Koristi se tamo gdje je jedan faktor puno važniji od drugoga
9	Apsolutno važniji	Koristi se u slučaju kada je jedna instanca apsolutno važnija od druge instance, bez ikakve dvojbe
2, 4, 6, 8	Međuvrijednosti	Koriste se kada je potreban kompromis između dvije vrijednosti. Odnosno, kada je teško odlučiti između dva neparna intenziteta važnosti

Ako je n broj prioriteta čije težine w_i treba odrediti na temelju njihovih omjera oni se izračunavaju na ovakav način [3]:

$$a_{ij} = \frac{w_i}{w_j}$$

Od tih omjera formiramo matricu relativnih važnosti A.

$$A = \begin{bmatrix} w_1/w_1 & w_1/w_2 & w_1/w_n \\ w_2/w_1 & w_2/w_2 & w_2/w_n \\ w_n/w_1 & w_n/w_2 & w_n/w_n \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{1n} \\ a_{21} & a_{22} & a_{2n} \\ a_{n1} & a_{n2} & a_{nn} \end{bmatrix}$$

Matrica A za slučaj konzistentnih procjena za koje vrijedi $a_{ij} = a_{jk} \cdot a_{kl}$ zadovoljava jednadžbu $A \cdot w = n \cdot w$ gdje je w vektor prioriteta. Problem rješavanja težina može se riješiti kao problem rješavanja jednadžbe $A \cdot w = \lambda \cdot w$, gdje je λ različit od nule.

$$\begin{bmatrix} w_1/w_1 & w_1/w_2 & \cdots & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \cdots & w_2/w_n \\ \cdots & \cdots & \cdots & \cdots \\ w_n/w_1 & w_n/w_2 & \cdots & w_n/w_n \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \cdots \\ w_n \end{bmatrix} = n \cdot \begin{bmatrix} w_1 \\ w_2 \\ \cdots \\ w_n \end{bmatrix}$$

Matrica A ima svojstva da je pozitivna, i recipročna jer sadrži elemente koji zadovoljavaju jednadžbu $a_{ij} = 1/a_{ji}$. Rang matrice je 1 i svi njezini redovi proporcionalni su prvom redu, zbog čega je samo jedna njezina svojstvena vrijednost različita od 0 i jednaka je n . Budući da je suma svojstvenih vrijednosti pozitivne matrice jednaka tragu te matrice odnosno sumi na dijagonali, svojstvena vrijednost različita od nule ima vrijednost n , tj. $\lambda_{max} = n$. Ukoliko matrica A sadrži nekonzistentnost, vektor težine w se može izračunati sustavom jednadžbi [3].

$$(A - \lambda_{max} \cdot I) \cdot w = 0 \quad \sum_i w_i = 1$$

Na temelju čega slijedi da težina pojedine alternative iznosi:

$$w_i = \frac{1}{n} \sum_j \frac{a^{ij}}{\sum_i a_{ij}}$$

3.3.3. Izračun lokalnih i globalnih prioriteta hijerarhijske strukture te provjera konzistentnosti

Izračun lokalnih i globalnih prioriteta alternativa svodi se na isti princip kao i kod izbora lokalnih i globalnih prioriteta kriterija. Svaka razina ima skup usporedaba, gdje se kriteriji i alternative uspoređuju u parovima. S jedne strane, kriteriji se uspoređuju u odnosu na vrhovni kriterij ili cilj, dok se alternative uspoređuju u odnosu na kriterije, redom. Donositelj odluke koristi Saatyevu skalu kako bi odredio intenzitet važnosti nekog kriterija ili alternative u odnosu na onu alternativu ili kriterij s kojom se uspoređuje. Za svaku razinu hijerarhijskog stabla provodi se analiza konzistentnosti, a opisana je u sljedećem potpoglavlju.

AHP metode koristi matematički model za izračun lokalnih prioriteta kriterija, podkriterija i alternativa, a potom se isti sintetiziraju u globalne prioritete alternativa. Globalni prioriteti alternativa su izračunati zbrajanjem lokalnih prioriteta navedenih alternativa ponderiranih s težinama elemenata više razine [5], [8].

3.3.4.Provođenje analize osjetljivosti

Sasvim je normalno da konačni poredak alternativa bude potpuno neizvjestan. Primjerice, da su za četiri alternative izračunate globalne važnosti redom 26%, 25%, 25% i 24%. To bi značilo da vrlo sitne promjene u rangiranju kriterija ili usporedbi alternativa mogu utjecati na konačnu odluku. Konačna odluka se donosi samo kada neka alternativa ima dovoljno veću globalnu važnost od drugih alternativa. Naravno, postoje mnogi načina za analiziranje osjetljivosti, npr. analiza performansi, analiza odnosa, gradijent analiza, dinamička analiza, itd. Općenito, analizu osjetljivosti definiramo kao ispitivanje utjecaja nezavisnih varijabli na zavisne varijable. U metodi AHP nezavisne varijable su usporedbe u parovima kriterija iz kojih dobijemo težine kriterija, te usporedbe alternativa u parovima iz kojih dobijemo lokalne prioritete alternativa. Zavisne varijable su konačni prioriteti alternativa [1].

3.3.5.Izbor alternative

Ukoliko je analiza osjetljivosti pokazala pozitivne rezultate, slijedi izbor alternative. Naravno, izabire se alternativa koja je na kraju procesa pokazala najveću globalnu važnost. Dakle, takva alternativa je imala najbolji prosjek relativnih lokalnih važnosti, odnosno, prema danim kriterijima pokazala se kao najbolja opcija. Ako, ipak, analiza osjetljivosti pokaže nezadovoljavajuće rezultate, tada bi trebalo ažurirati usporedbe pojedinih kriterija ili alternativa kako bi se došlo do konačnog rezultata.

3.4. Konzistentnost uspoređivanja u metodi AHP

AHP metoda svodi se na svega nekoliko računskih tehnika koje se koriste za cjelokupni izračun. Temelji se na izračunu važnosti kriterija i alternativa, a potom se njihovi rezultati koriste kao ulazna jedinica za generiranje izvješća. Primjerice, ako je tvrtka odlučila kupiti nekoliko službenih automobila, mora odlučiti između nekoliko modela. No, najprije je potrebno odlučiti po kojim kriterijima će se birati model automobila. Potom se određuje relativna važnost kriterija. Relativne važnosti kriterija rezultat su usporedbe pojedinih kriterija s ostalim kriterijima, u parovima. Svaka usporedba svodi se na odabir važnosti kriterija u odnosu na kriterij s kojim se uspoređuje, a odabir se vrši u vidu Saaty-eve skale.

Intenziteti važnosti prikazani u prethodnoj tablici predstavljaju interpretaciju omjera važnosti između dvaju kriterija. Ova skala izvedena je iz osnovnih načela generalizacije usporedaba u kontinuiranim slučajevima, čime kreiramo funkcionalnu jednadžbu, koja je nužan uvjet za rješavanje problema u realnim i složenim domenama [8], [10].

Kod svake usporedbe u parovima (engl. *Pairwise comparison*), svaki intenzitet važnosti može biti izabran. Naravno, intenzitet važnosti može se izabrati za oba kriterija u usporedbi u parovima. Dakle, ako je prvi kriterij apsolutno važniji od drugog kriterija pri donošenju odluke, tada se prvom kriteriju daje intenzitet važnosti 9 nad prvim kriterijem, dok se drugom kriteriju daje intenzitet važnosti 1/9. Naravno, moguć je izbor intenziteta važnosti od 1 do 9 u korist jednog kriterija nad drugim, no rijetkost je da je jedan kriterij apsolutno važniji od drugog kriterija, stoga se rijetko kojem kriteriju daje prednost intenziteta važnosti 8 ili 9.

Kod uspoređivanja kriterija u parovima, u metodi AHP kreira se i popunjava matrica usporedbi elemenata (kriterija ili alternativa).

Tabela 3 Primjer matrice usporedbi kriterija

Odabir modela službenih automobila	Cijena	Izgled	Marka	Prostranost
Cijena	1	2	3	4
Izgled	1/2	1	2	2
Marka	1/3	1/2	1	3
Prostranost	1/4	1/2	1/3	1

Tabela 3 preslika je sljedeće matrice:

$$C = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ c_{12} & c_{12} & \cdots & c_{12} \\ \vdots & \vdots & \ddots & \vdots \\ c_{12} & c_{12} & \ddots & c_{12} \end{bmatrix}$$

$$D = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 1/2 & 1 & 2 & 2 \\ 1/3 & 1/2 & 1 & 3 \\ 1/4 & 1/2 & 1/3 & 1 \end{bmatrix}$$

$$D = \begin{matrix} 25/12 & 4 & 19/3 & 10 \end{matrix}$$

Dakle, intenziteti važnosti pojedinih usporedaba postavljaju se na odgovarajuća mjesta unutar matrice. Nakon potpuno kreirane matrice usporedbi elemenata usporedbe,


kreće se na računanje relativnih vrijednosti istih. Uzeti ćemo kao primjer prethodno kreiranu tablicu usporedbi (Tablica 3.). Najprije je potrebno zbrojiti sve vrijednosti svakog stupca. U našem slučaju to su vrijednosti 9/4 za prvi stupac, 9/2 za drugi, 9/2 za treći te 9 za četvrti stupac.

Zatim se vrijednost svake ćelije matrice dijeli sa zbrojem stupca u kojemu se nalazi. Nakon navedenog izračuna dobijemo sljedeću matricu:

$$D = \begin{bmatrix} 12/25 & 1/2 & 9/19 & 2/5 \\ 6/25 & 1/4 & 6/19 & 1/5 \\ 4/25 & 1/8 & 3/19 & 3/10 \\ 3/25 & 1/8 & 1/19 & 1/10 \end{bmatrix} \gggg E = \begin{bmatrix} 0,463 \\ 0,251 \\ 0,186 \\ 0,1 \end{bmatrix}$$

Sada se izračunava prosječna vrijednost svakog retka (matrica E). Što znači da zbrojimo sve ćelije u pojedinom retku i podijelimo s brojem ćelije tog retka. Dobili smo relativne vrijednosti svakog elementa, a iznose redom 0.463, 0.251, 0.186, 0.1. Ovaj postupak zove se još *približni postupak*.

Slijedi izračun konzistentnosti kojom provjeravamo je li donositelj odluke dao intenzitete važnosti kriterija/alternativa koji su međusobno konzistentni. Ako je element x važniji od elementa y, a element y važniji od element z, tada zasigurno element x mora biti važniji od elementa z.



Slika 3 Primjer konzistentnih usporedbi elemenata

U prethodnom primjeru je lako prepoznati konzistentnost, no u nekim slučajevima biti će mnogo više elemenata pa se takva konzistentnost računa pomoću indeksa konzistentnosti AHP metode.

$$CI = \frac{(\lambda_{max} - n)}{(n - 1)}$$

Navedena formula se koristi za izračun konzistentnosti nekog skupa elemenata. Dakle, λ_{max} predstavlja maksimalnu svojstvenu vrijednost matrice usporedbi, dok n predstavlja broj redova dane matrice.

Omjer konzistentnosti se računa sljedećom formulom:

$$CR = \frac{CI}{RI}$$

gdje je RI slučajni indeks konzistentnosti kojeg možemo iščitati iz Tabele 4.

Tabela 4 Indeksi vrijednosti [5]

n	1	2	3	4	5	6	7	8	9	10
RI	0	0	0.58	0.9	1.12	1.24	1.32	1.41	1.45	1.49

Ukoliko je nakon navedenog izračuna vrijednost varijable CR manja od 0.1, tada su elementi konzistentni, odnosno donositelj odluke je ispravno unio intenzitete važnosti. U slučaju da je CR veći od 0.1, tada možemo zaključiti da uneseni intenziteti važnosti elemenata nisu konzistentni, stoga je potrebno promijeniti pojedine.

3.5. Aksiomi na kojima se temelji metoda AHP

Četiri su aksioma na kojima se temelji metoda AHP:

- Aksiom recipročnosti,
- Aksiom hijerarhije (zavisnosti),
- Aksiom homogenosti,
- Aksiom očekivanja.

3.5.1. Aksiom recipročnosti

Kada god radimo usporedbu u parovima, u obzir uzimamo oba člana kako bismo procijenili relativnu važnost jednog člana u odnosu na drugog. U prvom koraku moramo procijeniti koji je član važniji u usporedbi s drugim. Zatim procjenjujemo intenzitet razine njegove važnosti u odnosu na član s kojim se uspoređuje. Thomas L. Saaty je sljedećim aksiomom objasnio navedeno [8].

Ako je α skup n alternativa, a E skup kriterija u odnosu na koje se uspoređuje skup alternativa α . Za svaki $A_i, A_j \in \alpha$ i $C \in E$ vrijedi:

$$P_C(A_i, A_j) = \frac{1}{P_C(A_j, A_i)}$$

3.5.2.Aksiom hijerarhije

Djelomično uređeni skup je skup S s binarnom relacijom \leq ako zadovoljava sljedeće uvjete:

- Skup je refleksivan:
Za sve $x \in S, x \leq x$
- Skup je tranzitivan
Za sve $x, y, z \in S$,
ako vrijedi $x \leq y$ i $y \leq z$
tada vrijedi $x \leq z$
- Skup je antisimetričan
Za sve $x, y \in S$,
ako vrijedi $x \leq y$ i $y \leq x$
tada vrijedi $x = z$ (x i y se podudaraju)

Dekompozicija nalaže utjecaj nadelemenata na elemente pojedine razine, ukoliko postoji nadrazina. Što znači da elementi neke razine ovise o elementima druge razine, ukoliko pripadaju toj razini, te se s time postiže hijerarhijska struktura što je glavno sredstvo AHP metode. Stoga se proces usporedbe elemenata odvija prema razinama, gdje se prvo uspoređuju elementi određene razine u odnosu na elemente više razine, ukoliko viša razina postoji. Ipak, ako ne postoji viša razina određenog skupa elemenata, tada se vrši usporedba tih elemenata u odnosu na cilj.

3.5.3.Aksiom homogenosti

Aksiom homogenosti nalaže obaveznu homogenost svih elemenata koji sudjeluju u usporedbi, odnosno dopušta uspoređivanje članova samo ako su ti članovi usporedivi. Ukoliko se članovi ne nalaze na istoj razini neke hijerarhije, tada vršenje usporedbe tih članova nije moguće.

3.5.4.Aksiom očekivanja

Aksiom očekivanja kaže da nakon svake promjene hijerarhijske strukture mora slijediti ponovni izračun prioriteta novonastale hijerarhije. Primjerice, ako se članovi jedne razine međusobno uspoređuju u odnosu na njihovog roditelja u hijerarhijskoj strukturu, tada

se moraju ispuniti očekivanja da će zbroj svih stvarnih relativnih važnosti neke razine biti jednak stvarnoj relativnoj važnosti roditelja članova te razine. Ukoliko se članovi neke razine uspoređuju u odnosu na cilj, tada pojedinačne stvarne relativne važnosti svih članova iznose koliko i relativne važnosti istih, što znači da je njihov zbroj 1.

3.6. Grupno odlučivanje AHP metodom

Razlikujemo pozitivne i negativne aspekte grupnog donošenja odluka. U pozitivne aspekte svakako možemo uvrstiti da grupa često bolje razumije zašto postoji potreba za donošenjem odluke, znanje grupe je često veće od znanja pojedinca, grupa obično generira veći broj alternativa za rješavanje problema, participacija u odlučivanju povećava prihvaćanje odluke od strane članova grupe i odgovornost i rizik se dijele na članove grupe. Negativni aspekti grupnog odlučivanja su: dulje trajanje procesa donošenja odluke, opasnost od dominacije autoritativnog člana grupe ili skupnog mišljenja, pritisci za slaganjem mogu ograničavati i sputavati članove grupe, mogućnost konflikta i neslaganja između članova grupe, konkurencija između članova grupe može postati važnija od samog problema i postoji tendencija prihvaćanja prvog prihvatljivog rješenja [3].

U nastavku slijedi demonstracija izračuna matrice zajedničkih usporedbi temeljem 4 matrice individualnih procjena. Pojedinačne procjene agregiraju se u grupnu procjenu geometrijskom sredinom [11]. Primjer izračuna zajedničke procjene za prvi redak, drugi stupac: $\sqrt[4]{3 \cdot 2 \cdot 3 \cdot 4} = 2.91$

$$\begin{bmatrix} 1 & 3 & 6 & 8 \\ 1/3 & 1 & 3 & 4 \\ 1/6 & 1/3 & 1 & 1 \\ 1/8 & 1/4 & 1/2 & 1 \end{bmatrix} \quad \begin{bmatrix} 1 & 2 & 5 & 7 \\ 1/2 & 1 & 2 & 5 \\ 1/5 & 1/2 & 1 & 1 \\ 1/7 & 1/5 & 1/2 & 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 3 & 4 & 7 \\ 1/3 & 1 & 3 & 6 \\ 1/4 & 1/3 & 1 & 1 \\ 1/7 & 1/6 & 1/2 & 1 \end{bmatrix} \quad \begin{bmatrix} 1 & 4 & 5 & 6 \\ 1/4 & 1 & 3 & 5 \\ 1/5 & 1/3 & 1 & 1 \\ 1/6 & 1/5 & 1/2 & 1 \end{bmatrix}$$

Agregirana matrica.

$$\begin{bmatrix} 1 & 2.91 & 4.95 & 6.96 \\ 0.34 & 1 & 2.71 & 4.73 \\ 0.2 & 0.37 & 1 & 1 \\ 0.14 & 0.21 & 0.5 & 1 \end{bmatrix}$$

Nakon što je provedeno grupno odlučivanje, dobivaju se rezultati koji se dalje mogu analizirati i implementirati posebno za svakog sudionika procesa ili grupno kao sinteza rezultata sudionika procesa grupnog odlučivanja.

4. Razvoj softvera

4.1. Opis postojećeg stanja

Uz pomoć mentora, prepoznata je potreba za razvijanje softvera za podršku pri odlučivanju. Planirano je da se navedeni softver za početak koristi u sklopu Fakulteta organizacije i informatike, no ne odbacuje se mogućnost širenja na višu razinu. Softver je prvotno namijenjen za potrebe studenata Fakulteta organizacije i informatike na kolegijima čiji nastavni plan uključuje odlučivanje pomoću AHP metode. No, ne odbacuje se i mogućnost uvođenja novih tehnika odlučivanja u navedenu aplikaciju.

Da bismo lakše prepoznali važnost pojedinih koraka u razvoju ovog softvera, potrebno je shvatiti problem koji potiče razvitak istoga. Iako trenutno postoji mnogo aplikacija koje se bave ovom tematikom, smatram da esencijalnost strateškog odlučivanja u današnjem svijetu zahtjeva njih mnogo više. Pronašao sam nekoliko navedenih aplikacija koje ne pružaju dovoljno funkcionalnosti za neometano korisničko iskustvo pri donošenju odluka.


Prije svega, smatram da aplikacija koja rješava ovaj problem, korisnicima mora omogućiti dodavanje kriterija do n -te razine, umjesto ograničavanja dodavanja kriterija, primjerice, do treće razine. Isto tako, vrlo je važno korisnicima omogućiti definiranje stvarnih vrijednosti alternativa prema svim kriterijima (upisivanje matrice vrijednosti alternativa), koji olakšavaju uspoređivanje alternativa u parovima u odnosu na kriterije. Pojedine aplikacije nemaju implementiranu analizu osjetljivosti, što je također jedan od većih problema. Važan element aplikacije je i izrada izvještaja koje obuhvaća sve bitne elemente u rješavanju problema odlučivanja. Prilikom razvitka softvera za podršku odlučivanju korištenjem AHP metode, pridodavao sam važnosti implementaciji prethodno navedenih problema.

Kroz zadnjih nekoliko godina vidjeli smo nagli porast količine web i mobilnih aplikacija, dok se *desktop* aplikacije sve manje koriste, a samim time i razvijaju. Iako su desktop aplikacije mnogo bolje po pitanju sigurnosti, web aplikacije stječu prednost u pogledu prenosivosti (engl. *Portability*) i održivosti. Primjerice, desktop aplikacije, za razliku od web aplikacija, zahtijevaju manualno ažuriranje aplikacije što je velika mana. Isto tako, desktop aplikacije se posebno razvijaju za svaku platformu, dok je za pokretanje web aplikacija potreban moderni poslužitelj. Kako bih bio u skladu s trendom, odlučio sam ovaj softver razvijati u obliku web aplikacije. Smatram da ću na taj način omogućiti lakši pristup aplikaciji, te time ostvariti i veći broj potencijalnih korisnika.

4.2. Korišteni alati, tehnologije i programski jezici

S obzirom da sam se orijentirao na razvijanje web aplikacije, a prethodno sam stekao iskustvo u radu s .NET tehnologijom, odlučio sam koristiti *Microsoft-ov ASP.NET* razvojni okvir u kombinaciji s C# programskim jezikom. U *frontend* dijelu aplikacije koristio sam *Javascript* programski jezik u kombinaciji sa *HTML-om* i *CSS-om*. Također, za olakšani razvoj sam koristio *AngularJS open-source* razvojni okvir čiji je razvitak započeo *Google*. Također, koristio sam *Microsoft-ovo* integrirano razvojno okruženje (engl. *IDE – Integrated development environment*) *Visual Studio* za razvoj ovog softvera. Uz navedeno, koristio sam mnogo različitih izvora koje sam sjedinio sa svojom aplikacijom radi lakšeg rješavanja problema te bolji dizajn korisničkog sučelja. Naknadno, prilikom razvijanja grafikona u sklopu analize osjetljivosti, pojavila se potreba za korištenjem *ChartJs open-source* programskog paketa.

Danas je najkorištenija MVC arhitektura (engl. *Model, view, controller architecture*) za razvoj web aplikacija, pa sam se tako i ja odlučio za istu. MVC je arhitektura koja razdvaja programski kod u tri dijela, čineći tako funkcionalnu cjelinu čiji je programski kod čitljiviji nego kod običnih arhitektura. MVC tako dijeli aplikaciju na *Model* koji je zaslužan za definiranje modela baze podataka, *View* koji je uglavnom napisan u *HTML-u*, *CSS-u* i *Javascriptu* te predstavlja prezentacijski sloj aplikacije, te *Controller* u kojemu se nalazi poslovna logika aplikacije.



Slika 4 MVC arhitektura [15]

4.3. Funkcionalnosti

Jasno je da ovakav softver nudi široki spektar mogućnosti razvoja. Iako je prvotni plan bio razvoj softvera za provođenje AHP metode, ne isključuje se mogućnost širenja u vidu ostalih metoda za podršku pri odlučivanju. Tijekom pisanja ovog diplomskog rada,

pojedine funkcionalnosti još uvijek nisu u potpunosti testirane, stoga su moguće pogreške u radu. U nastavku slijedi popis funkcionalnosti te njihov opis:

- Kreiranje novog projekta te ažuriranje i brisanje postojećeg: Prilikom kreiranja projekta korisnik ima mogućnost upisati naziv novog projekta te ga ukratko opisati. Naziv i opis projekta je moguće naknadno ažurirati, a projekt se može i obrisati.
- Dodavanje, ažuriranje i brisanje alternativa: Za pojedini projekt moguće je dodati neograničeni broj alternativa. Prilikom kreiranja alternativa korisnik može upisati naziv i opis alternative. Također, naziv i opis alternative moguće je naknadno ažurirati.
- Dodavanje i brisanje kriterija: Za početak se kriteriji dodaju u odnosu na glavni cilj projekta, a zatim je moguće dodati kriterije na neograničeni broj razina. Bitno je da je na jednoj razini minimalno dva kriterija.
- Definiranje stvarnih vrijednosti alternativa po svim kriterijima: Za svaku alternativu moguće je definirati stvarne vrijednosti svih kriterija, primjerice količina RAM memorije za određenu alternativu mobilnog uređaja
- Uspoređivanje kriterija u parovima kroz sve razine: Na svakoj razini kreirane hijerarhijske strukture potrebno je usporediti svaki kriterij sa svakim. Pri tome se mora paziti da su usporedbe konzistentne. Kod svake promjene intenziteta važnosti usporedbe mijenja se i konzistentnost kriterija te upozorava korisnika ukoliko razina nije konzistentna. Usporedbe se vrše prema Saaty-evoj skali.
- Uspoređivanje alternativa u parovima u odnosu na kriterije: Za svaki definirani kriterij potrebno je međusobno usporediti sve postojeće alternative. Prilikom usporedbe prikazane su stvarne vrijednosti alternativa za kriterij prema kojemu se uspoređuju. Na taj način je korisniku omogućeno lakše određivanje intenziteta važnosti pojedinog kriterija u odnosu na drugog. Kao i kod kriterija, aplikacija upozorava korisnika o konzistentnosti/nekonzistentnosti alternativa za određeni kriterij.
- Računanje globalnih vrijednosti alternativa i prikaz rezultata: Nakon uspješnih provedbi usporedbi u parovima, korisniku se prikazuje konačni poredak alternativa te izračunate globalne vrijednosti. Također, korisniku je prikazan *plot* dijagram za lakše prepoznavanje razlike između globalnih vrijednosti alternativa.
- Analize osjetljivosti: Nakon prikaza rezultata korisnik ima mogućnost analizirati osjetljivost donesene odluke. Dakle, analizom osjetljivosti korisnik provjerava mijenja li se konačni poredak alternativa promjenom vrijednosti kriterija. U aplikaciji su dostupni *Head-To-Head sensitivity* dijagram, *Performance sensitivity* dijagram, *Dynamic sensitivity* dijagram te jedan prilagođeni dijagram. Osim *Head-To-Head*, sve analize osjetljivosti su dinamičke, odnosno omogućuju interakciju korisnika.

- Spremanje analiza osjetljivosti za kasnije korištenje: Kako bi se analiza osjetljivosti mogla naknadno pregledavati i dodavati u izvještaj, aplikacija, korisničkim pritiskom na gumb, sprema pojedinu analizu osjetljivosti u obliku *png* slike.
- Kreiranje projektnog izvještaja: Nakon uspješne provedbe usporedbe kriterija i alternativa te analize osjetljivosti, korisnik može izabrati opciju za kreiranje izvještaja. Aplikacija potom kreira izvještaj prilagođen željama korisnika. U izvještaj su uključeni:
 - naziv i opis projekta
 - popis kriterija te njihovih globalnih i lokalnih vrijednosti
 - prikaz usporedba kriterija u parovima
 - popis alternativa
 - konačni poredak alternativa uz prikaz globalnih vrijednosti
 - prikaz stvarnih vrijednosti alternativa prema kriterijima
 - dodane analize osjetljivosti

4.4. Osnove razvoja softvera

Razvoj softvera za podršku odlučivanju korištenjem AHP metode započeo je definiranjem ERA modela. Iako se sve češće koristi *Code first* pristup razvoja baza podataka, u ovom projektu odlučio sam koristiti *Database first* pristup. Kao što sam naziv kaže, *Database first* pristup razvoju projekta temelji se na početnom definiranju baze podataka na temelju koje se kasnije razvija projekt. Za početak sam kreirao osnovne entitete unutar baze podataka, no dodavši nove funkcionalnosti aplikaciji, paralelno sam dodavao i entitete za kojima se pojavila potreba. Na slici 5. prikazan je ERA model baze podataka koji se sastoji od svega 16 entiteta, od kojih je 7 slabih entiteta.

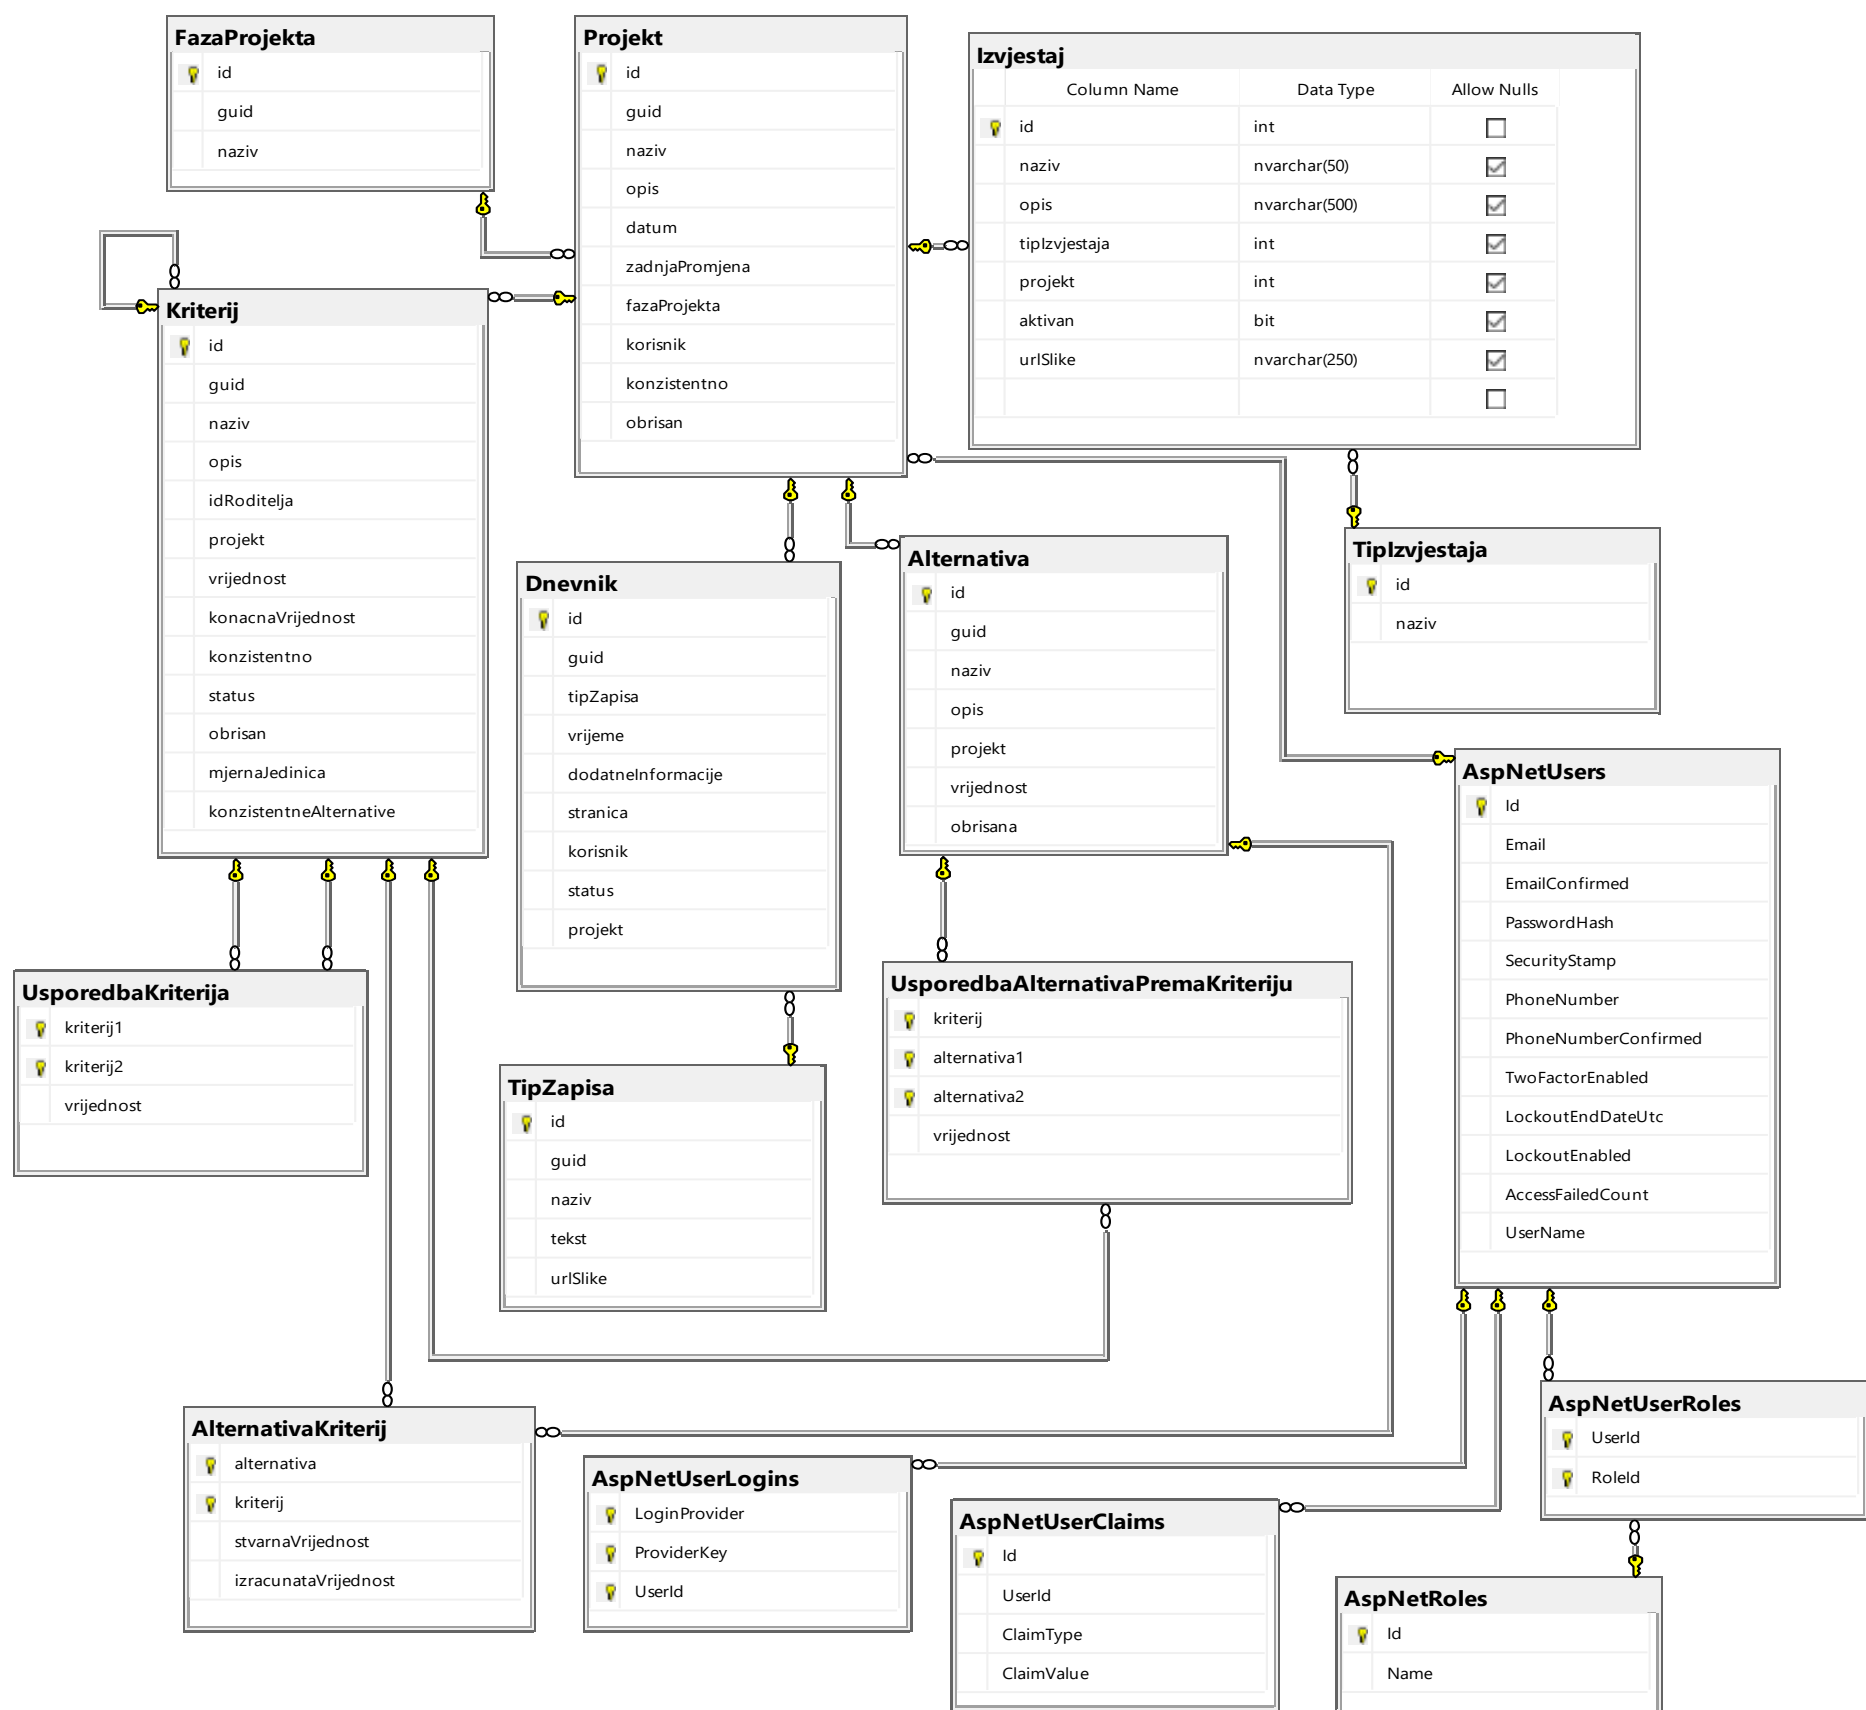
Najvažniji entitet, prikazan na prethodnom ERA modelu, je entitet *Projekt*. Navedeni entitet predstavlja instancu projekt kojeg je kreirao korisnik (*AspNetUsers*). Svaki korisnik može kreirati beskonačno mnogo projekata, dok jedan projekt pripada samo jednom korisniku. Svaki projekt sadrži 0 ili više kriterija, a svaki kriterij pripada točno jednom projektu, a jednako vrijedi i za alternative. Reference *kriterij ima kriterij* predstavlja hijerarhijsku strukturu entiteta *Kriterij*. To znači da svaki kriterij može pripadati nijednom ili jednom kriteriju. Ukoliko neki kriterij ne pripada niti jednom kriteriju, tada možemo reći da taj kriterij pripada najvišoj razini hijerarhijskog stabla nekog projekta. Ako ipak neki kriterij pripada drugom kriteriju, možemo reći da je taj kriterij podkriterij tog kriterija. Kada korisnik u paru usporedi dva kriterija iste razine, tada se izračunata vrijednost zapisuje u tablicu *UsporedbaKriterija*. Entitet *Alternativa* predstavlja svaku instancu alternative nekog projekta koju je korisnik ručno dodao. Alternativa se isključivo može uspoređivati s ostalim

alternativama u odnosu na neki kriterij. Intenziteti važnosti, dobiveni navedenim usporedbama alternativa u paru, zapisuju se u tablicu *UsporedbaAlternativaPremaKriteriju*. Izračunata lokalna vrijednost alternative, u odnosu na neki kriterij, zapisuje se u tablicu *AlternativaKriterij*. Nakon što smo dobili sve moguće lokalne vrijednosti alternativa, izračunava se globalna vrijednosti, te se potom zapisuje u tablicu *Alternativa*. *AspNetUsers*, *AspNetUserLogins*, *AspNetUserClaims*, *AspNetRoles* i *AspNetUserRoles* je skup entiteta koje je kreirao *Microsoft*-ov sustav identiteta (engl. *Identity system*) za olakšano kreiranje funkcionalnosti registracije i prijave korisnika unutar aplikacije.

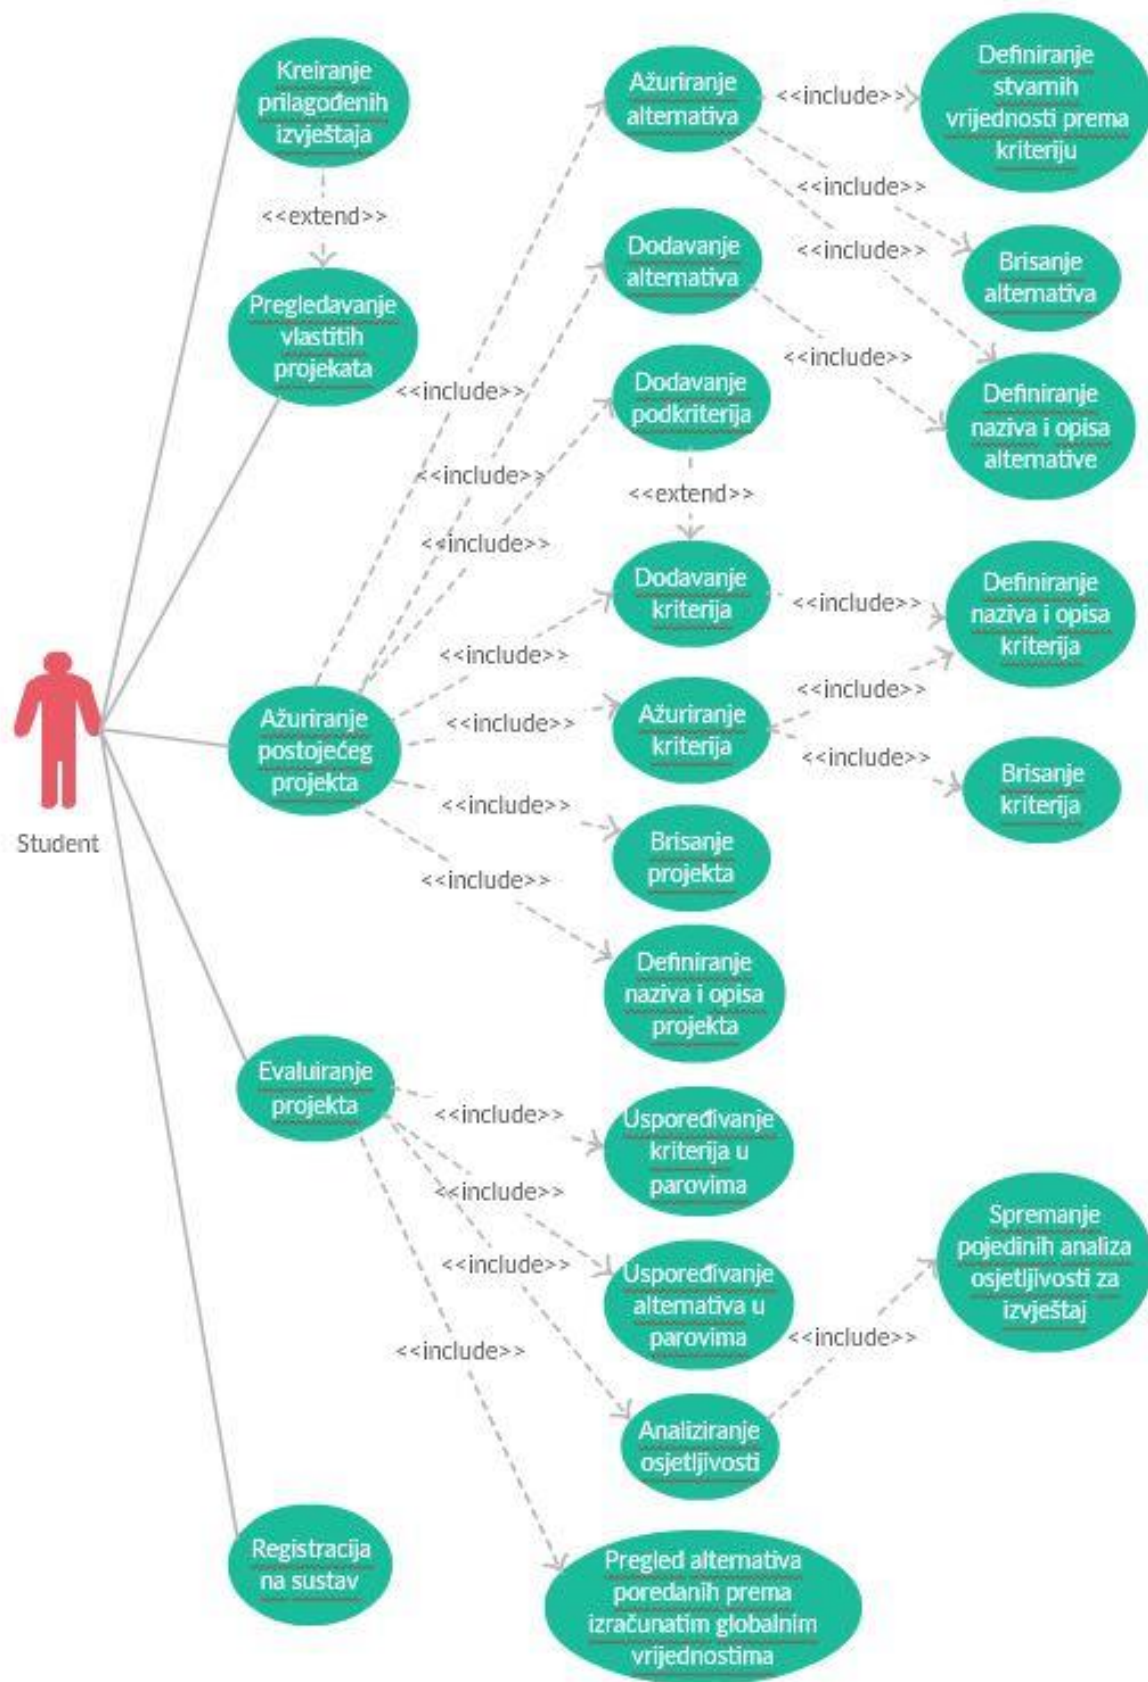
Dijagram slučajeva korištenja je jednostavan oblik prezentacije korisničke interakcije sa sustavom (Slika 6.). Preciznije, prikazuje mogućnosti interakcije učesnika sa navedenim sustavom te pojašnjava kako sustav reagira na korisničku interakciju. Na dijagramu je vidljivo da sustav ima nekoliko glavnih funkcionalnosti koje se dijele na više podfunkcionalnosti. Glavne funkcionalnosti sustava, iz perspektive studenta kao korisnika, su:

- Registracija na sustav
- Pregledavanje vlastitih projekata
- Upravljanje projektima (kreiranje i ažuriranje projekata)
- Evaluacija projekta

Ažuriranje projekata uključuje funkcionalnosti ažuriranja naziva i opisa projekata, kreiranje i ažuriranje alternativa te kriterija, kreiranje podkriterija i brisanje projekata. Kreiranje prilagođenih izvještaja proširuje funkcionalnost pregleda postojećih projekata. Funkcionalnost evaluacije projekata uključuje uspoređivanje kriterija u parovima, uspoređivanje alternativa u parovima u odnosu na kriterij, pregledavanje poretka alternativa prema izračunatim globalnim vrijednostima. Također, u navedenu funkcionalnost je uključeno analiziranje osjetljivosti koje je prošireno funkcionalnošću spremanja kreiranih analiza osjetljivosti u obliku slika.



Slika 5 ERA model



Slika 6 Dijagram slučaja korištenja

4.5. Mogućnosti proširenja

Postoje razne mogućnosti proširenja kreiranog sustava za podršku odlučivanju. Možemo započeti s ciljanom skupinom korisnika. Primjerice, za početak je planirano prezentiranje ovog projekta studentima koji na Fakultetu organizacije i informatike pohađaju kolegije čiji nastavni plan uključuje odlučivanje korištenjem AHP metode. Naknadno, ovaj sustav je moguće razviti do razine u kojem će ga koristiti i studenti s ostalih fakulteta. Isto tako, ne isključuje se mogućnost korištenja u poslovne svrhe, npr. donošenje strateških odluka unutar organizacija radi unaprjeđenja poslovanja.

Iako se nalazi na samom vrhu zbog svih njezinih kvaliteta, AHP metoda ima i svoje mane, što je sasvim normalno. Mnogo znanstvenika tvrdi da tablica indeksa konzistentnosti nije precizno definirana. Tako se pojavila FAHP ideja koja koristi takozvane nejasne brojeve (engl. *Fuzzy numbers*) [12]. Stoga, smatram da je s vremenom moguće nadograditi aplikaciju u vidu dodavanja funkcionalnosti korištenja nejasnih brojeva umjesto definiranih indeksa konzistentnosti.

Moguća su razna proširenja u vidu konzistentnosti intenziteta važnosti kriterija i alternativa. Jedno od njih je mogućnost razvijanja podsustava za prepoznavanje elemenata s visokim intenzitetom osjetljivosti. Takav sustav bi prepoznao elemente s visokim intenzitetom osjetljivosti te upozorio korisnika na potrebu za što preciznijim definiranjem intenziteta važnosti u usporedbama u parovima. Uz to, mogao bi korisniku pokazati na koji način odrediti intenzitet važnosti nekog elementa u odnosu na drugog, a da pritom ne njegova odluka ne utječe na rušenje praga konzistentnosti.

Grupno odlučivanje je zasigurno najpotrebnije potencijalno proširenje ovog sustava za potporu odlučivanju. Grupno odlučivanje provođenjem AHP metode svodi se na pojedinačno uspoređivanje kriterija i alternativa u parovima, koje rezultira dobivanjem lokalnih vrijednosti. Potom se izračunate lokalne vrijednosti svakog člana sintetiziraju u konačne globalne vrijednosti kriterija, koje se koriste za izračun globalnih vrijednosti alternativa. Iako još nije dokazano, smatra se da je grupno odlučivanje preciznije od pojedinačnog. Grupa ljudi ima tendenciju donošenja odluke koje su ekstremnije od onih koje donose pojedinci, u smjeru individualnih sklonosti [13]. Osim prethodno definiranih mogućnosti proširenja softvera, postoje i opća proširenja. Npr. dodavanje novih analiza osjetljivosti, mogućnost prijave na sustav preko posrednika za prijavu, kao što su Facebook, Google ili AAI@EduHr.

4.6. Pregled softverskih funkcionalnost

U ovom poglavlju pokušati ću u što kraćim crtama prikazati kreirani sustav za potporu odlučivanju. Aplikacija je minimalističkog dizajna, bez mnoštva nepotrebno prikazanih podataka i opcija, a pristup aplikaciji imaju samo registrirani korisnici. Na slici 7 prikazan je obrazac za prijavu i registraciju korisnika.

Nakon prijave u sustav, korisnik se preusmjerava na početnu stranicu koja predstavlja pregled postojećih projekata korisnika. Na ovoj stranici, svaki projekt definirane je nazivom, opisom, fazom u kojoj se nalazi, vremenom kreiranja projekta te brojem alternativa i kriterija. Postoje sljedeće faze projekta:

- Kreiran – opisuje projekte koji su kreirani, no nemaju definiranih alternativa i kriterija
- U izradi – uključuje projekte koji imaju dodatne alternative i kriterije, no konačni rezultat još nije dobiven
- Završen – opisuje projekte koji imaju definirane alternative i kriterije, izračunate lokalne i globalne vrijednosti istih, te konačan rezultat

Na Slici 9 prikazan je obrazac za dodavanje novog projekta, gdje je potrebno dodati naziv i opis projekta. Nakon što je korisnik dodao novi projekt, isti se pojavio u listi postojećih projekata. Ako korisnik odabere pojedini projekt iz liste svojih projekata, otvara mu se početna stranica tog projekta. Na početnoj stranici su prikazane osnovne informacije o projektu, lista alternativa i hijerarhijski pregled kriterija (Slika 9. i 10.). Na početnoj stranici projekta postoje razne opcije za upravljanje projektom, alternativama i kriterijima. Primjerice, moguće je dodavanje karakteristika postojećim alternativama za svaki kriterij (Slika 12.), ažuriranje naziva i opisa projekta, dodavanje kriterija i podkriterija, itd.

The image displays two white rectangular forms on a teal background. The left form is titled 'Registracija' and contains three input fields labeled 'Mail adresa', 'Lozinka', and 'Ponovljena lozinka', followed by a 'Registriraj se' button. The right form is titled 'Prijava' and contains two input fields labeled 'Mail adresa' and 'Lozinka', followed by a 'Prijavi se' button. A horizontal line with the word 'or' in the center separates the two forms.

Registracija

Mail adresa

Lozinka

Ponovljena lozinka

Registriraj se

or

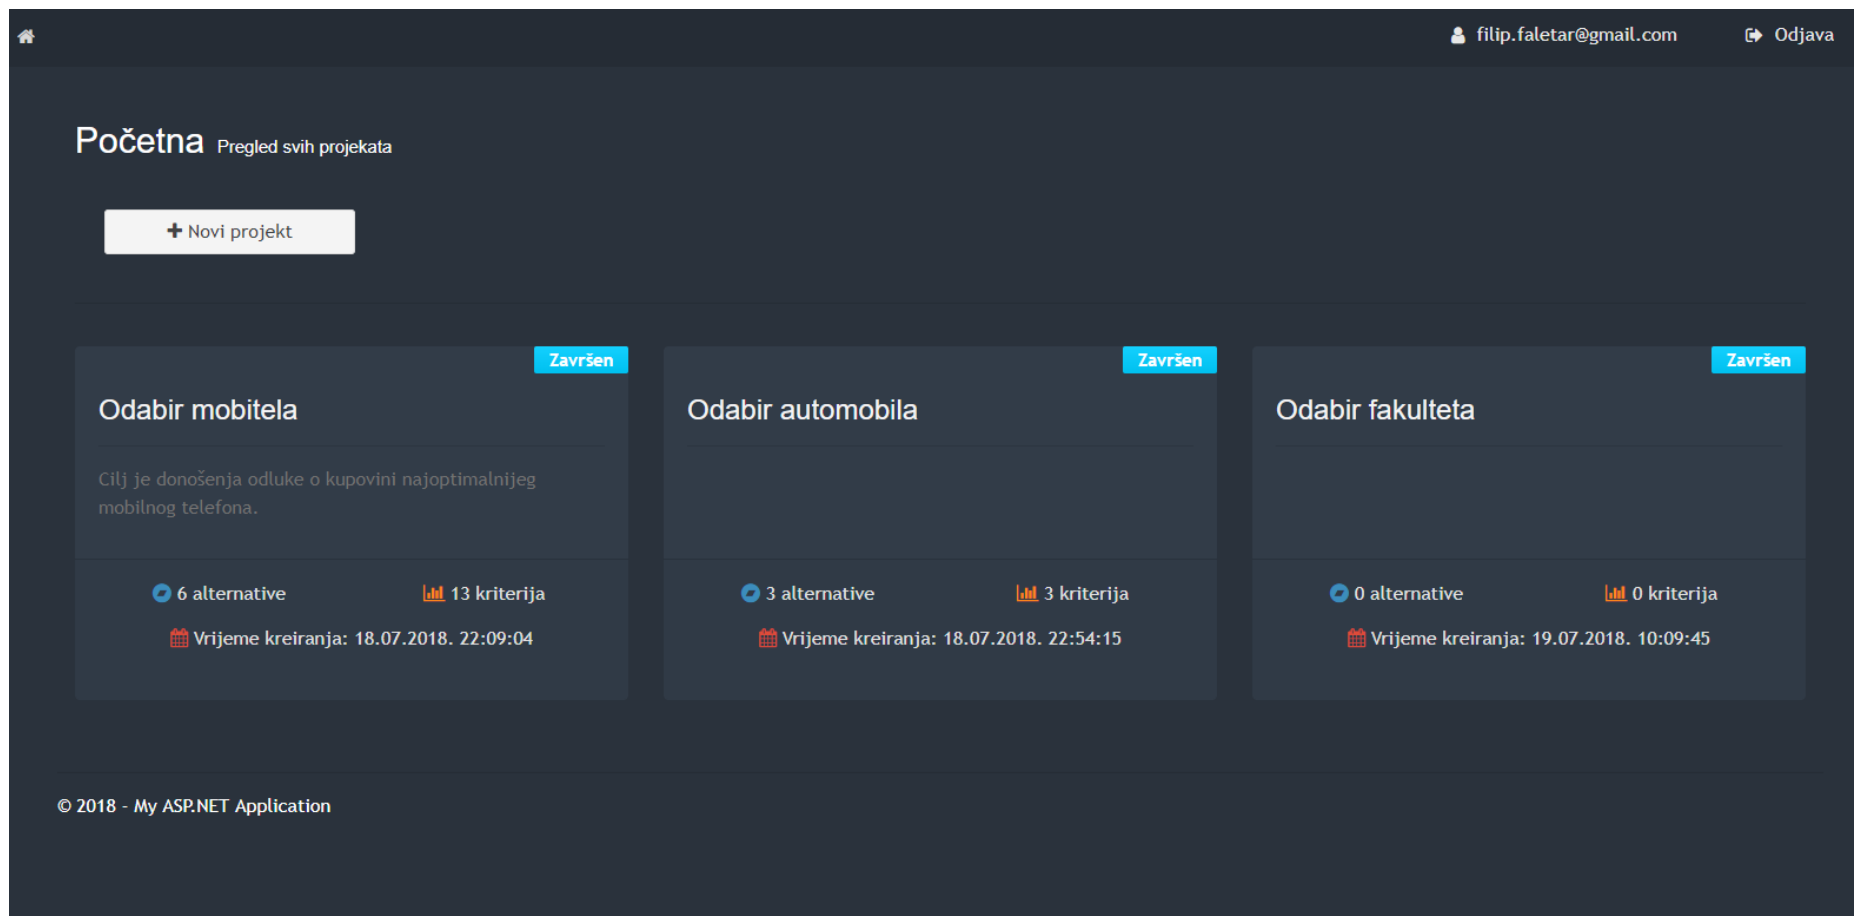
Prijava

Mail adresa

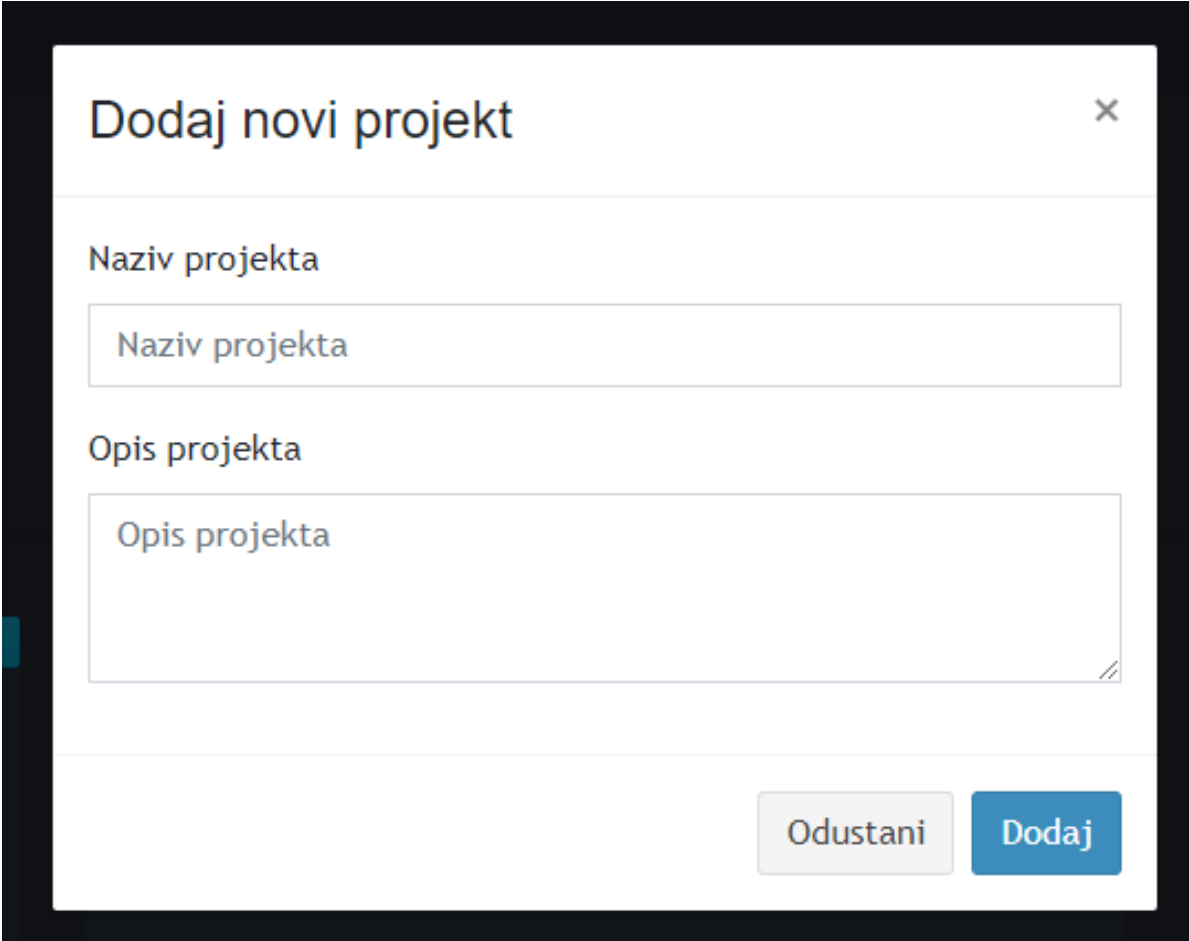
Lozinka

Prijavi se

Slika 7 Obrasci za registraciju i prijavu korisnika



Slika 8 Početna stranica - pregled postojećih projekata



Dodaj novi projekt ✕

Naziv projekta

Naziv projekta

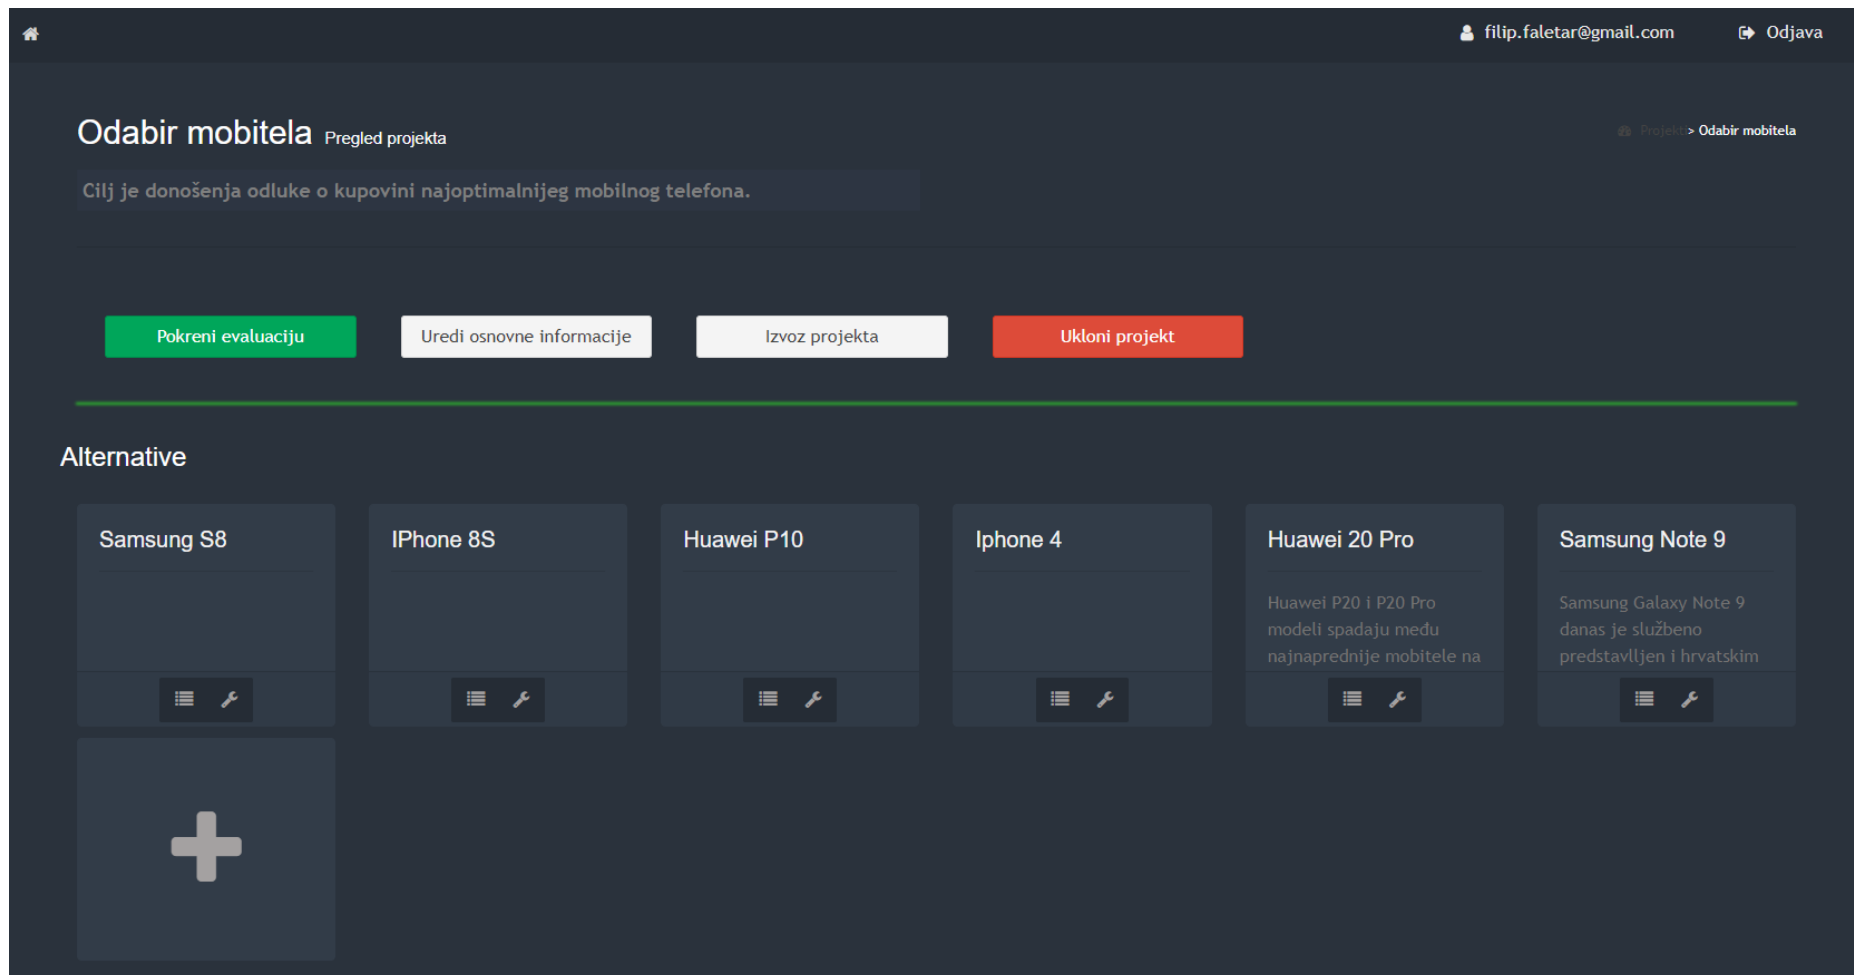
Opis projekta

Opis projekta


Odustani

Dodaj












Slika 9 Obrazac za kreiranje novog projekta



Slika 10 Pregled osnovnih informacija projekta i alternativa


filip.faletar@gmail.com
Odjava

Kriteriji

> Izgled	15,22%	+	
> Gumbi	2,54%	16,67%	+ 
> Ekran	12,69%	83,33%	+ 
> Performanse	31,9%	+	
> CPU	6,23%	19,52%	+ 
> RAM	5,66%	17,74%	+ 
> Memorija	13,79%	43,21%	+ 
> Kamera	6,23%	19,52%	+ 
> Marka	8,04%	8,04%	+ 
> Cijena	12,53%	12,53%	+ 
> Staklo	8,25%	8,25%	+ 
> Software	15,79%	15,79%	+ 
> Zvučnici	8,25%	8,25%	+ 

Slika 11 Pregled kriterija

Karakteristike Samsung S8 prema kriterijima



Marka

Samsung

CPU

i7

RAM

8 gb

Gumbi

Stvarna vrijednost alternative po kriteriju

Ekran

Stvarna vrijednost alternative po kriteriju

Cijena

7200 kn

Staklo

Gorilla glass Premium

Memorija

32 gb (proširivo do 64 gb)

Kamera

12 mgpx

Software

Android

Zvučnici

Premium

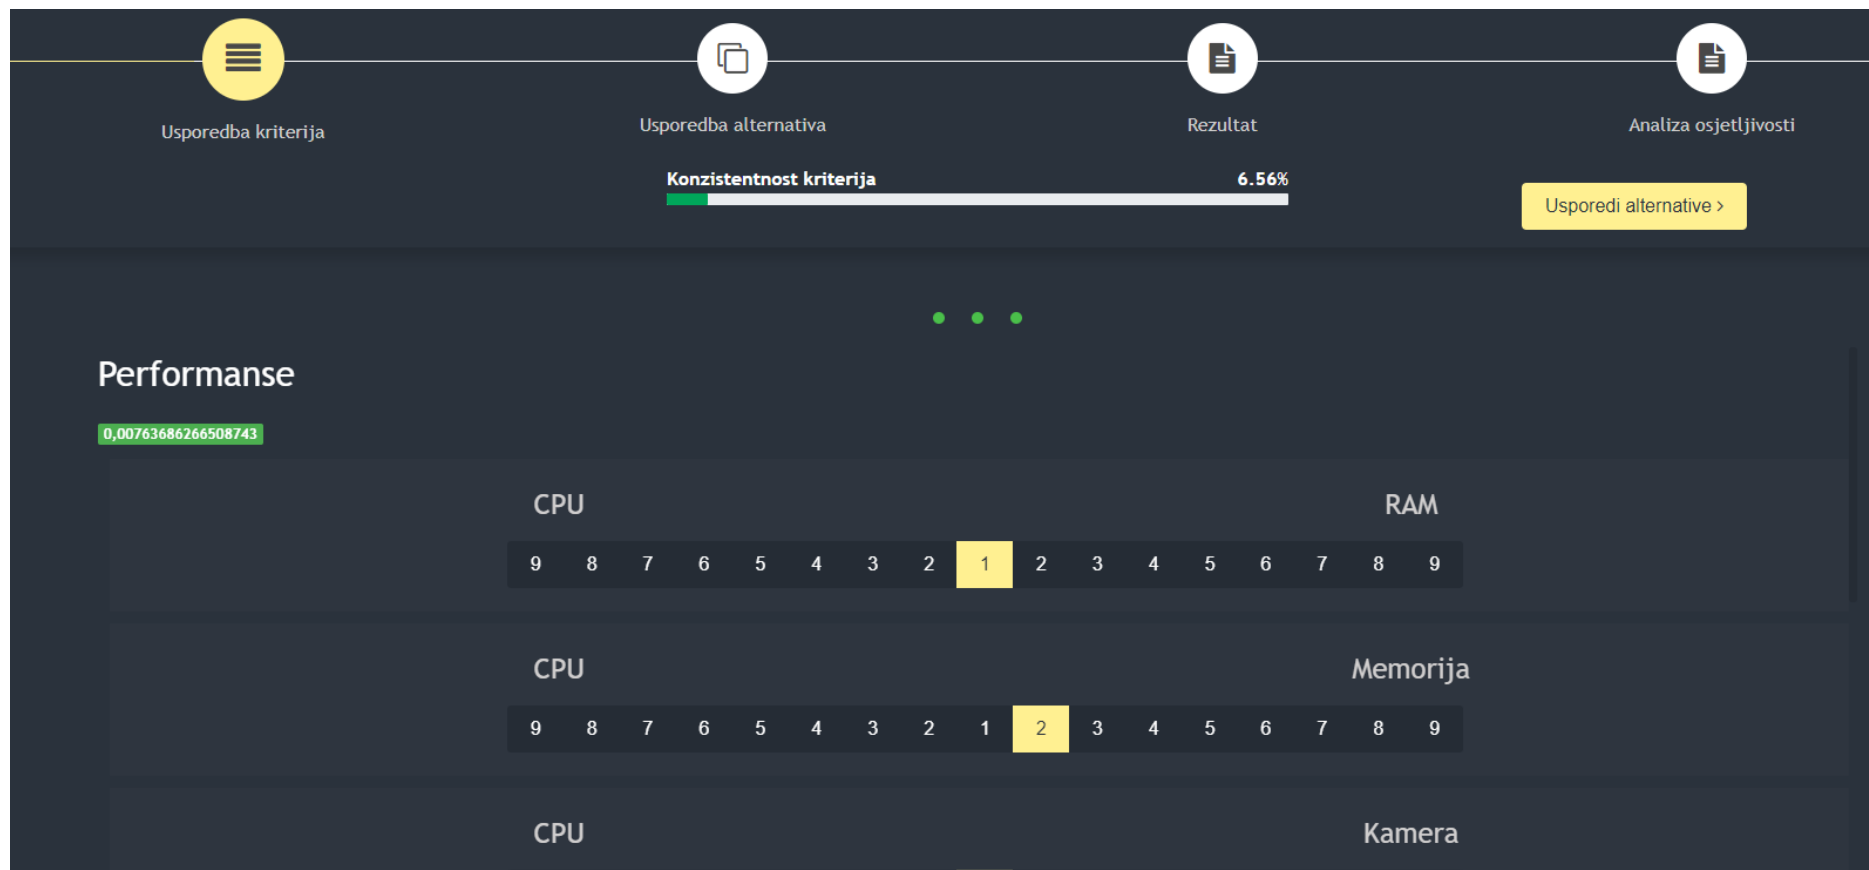
Odustani

Spremi promjene

Slika 12 Ažuriranje karakteristika alternativa prema kriterijima

Najvažniji dio ove web aplikacije je sustav za evaluaciju koji se sastoji od četiri koraka. Prvi korak je dio za usporedbu kriterija u parovima, gdje se svaki kriterij uspoređuje s kriterijima na istoj razini hijerarhijskog stabla. Konzistentnost svake razine prikazan je u gornjem lijevom kutu (Slika 13.). Na vrhu evaluacijskog obrasca vidljiva je konzistentnost svih kriterija unutar projekta. Ukoliko je vrijednost veća od 10%, projekt nije konzistentan. Treći korak evaluacije je „Rezultat“. U ovom koraku prikazan je poredak alternativa prema izračunatim globalnim vrijednostima. Također, prikazan je i dijagram koji nam daje bolji uvid vrijednosti alternativa (Slika 15.)

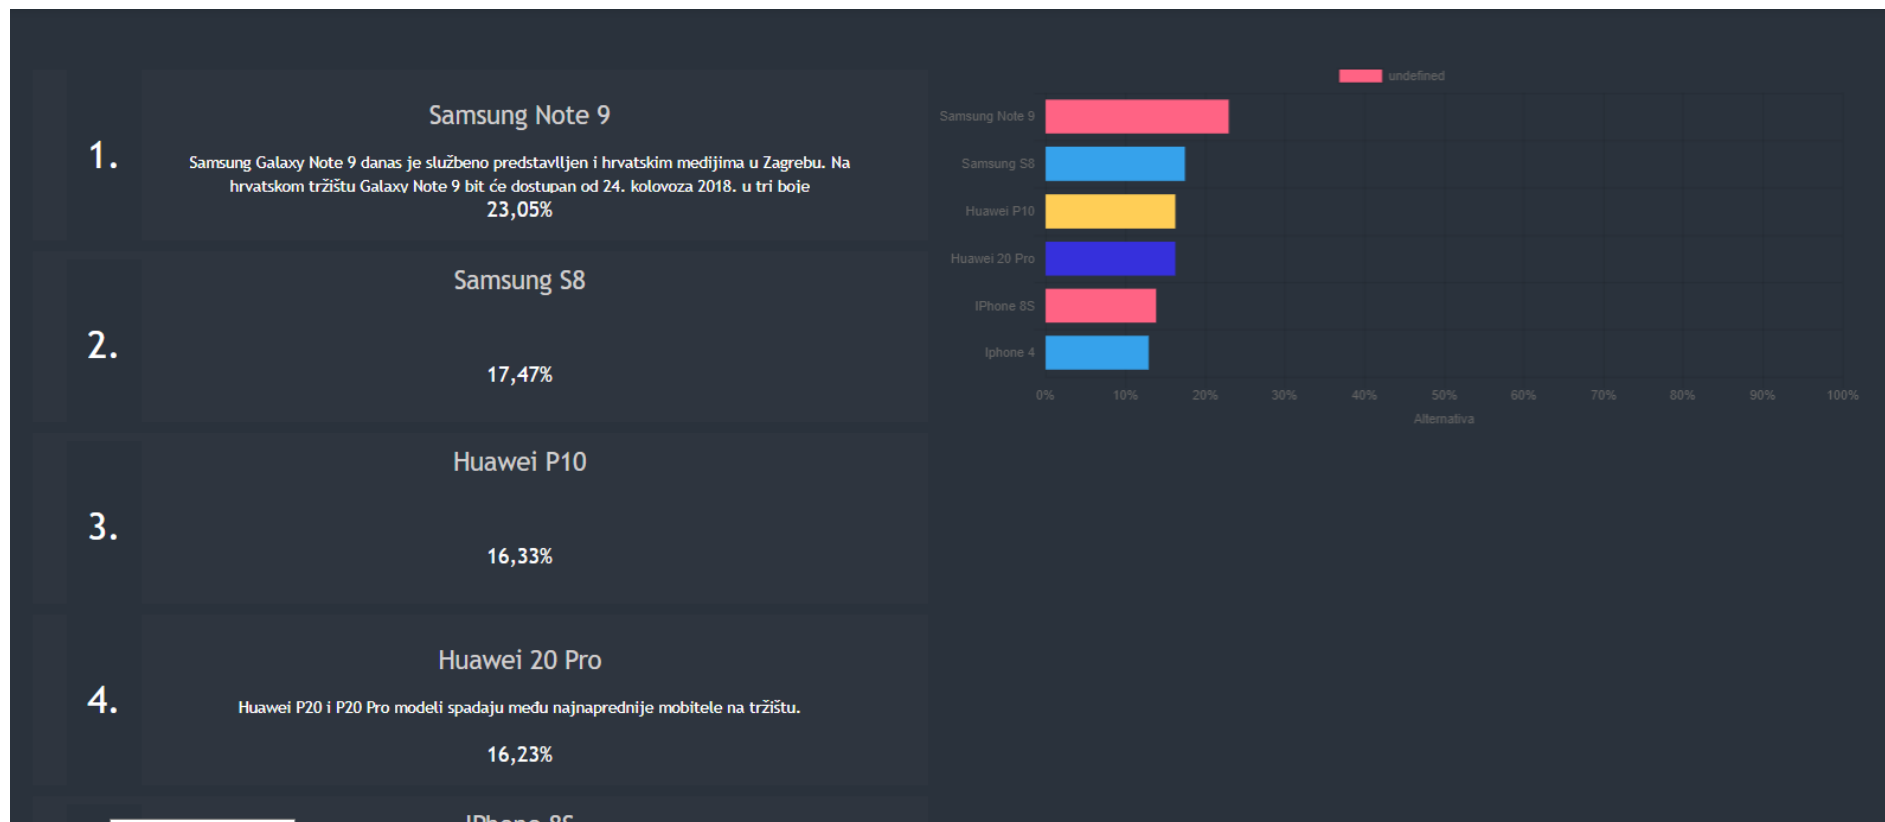
Posljednji korak evaluacije uključuje dosad nepoznatu analizu osjetljivosti koja prikazuje utjecaj promjene veličine pojedinih usporedbi u parovima na prioritete. Ovaj graf je dinamički. Dakle, promjenom pojedine usporedbe u paru, ažurira se graf, te nam pokazuje koliki utjecaj navedena promjena ima na krajnji poredak alternativa (Slika 16). Vodoravne crte su fiksne i predstavljaju globalne vrijednosti alternativa temeljene na stvarnim rezultatima evaluacije. Stupci predstavljaju jednake vrijednosti, no oni su dinamični, što znači da reagiraju na korisničku promjenu intenziteta važnosti pojedine usporedbe kriterija. Vidljivo je da vrijednost alternative „Samsung Note 9“ pala za nekoliko posto nakon korisničke interakcije. Također, iznad grafa vidljiv je gumb „Spremi za izvoz“. Pritiskom na taj gumb korisniku se otvara obrazac pomoću kojeg definira naziv i opis slike koju je upravo spremio (Slika 17.). Spremljena slika kasnije se može koristiti za kreiranje izvještaja.



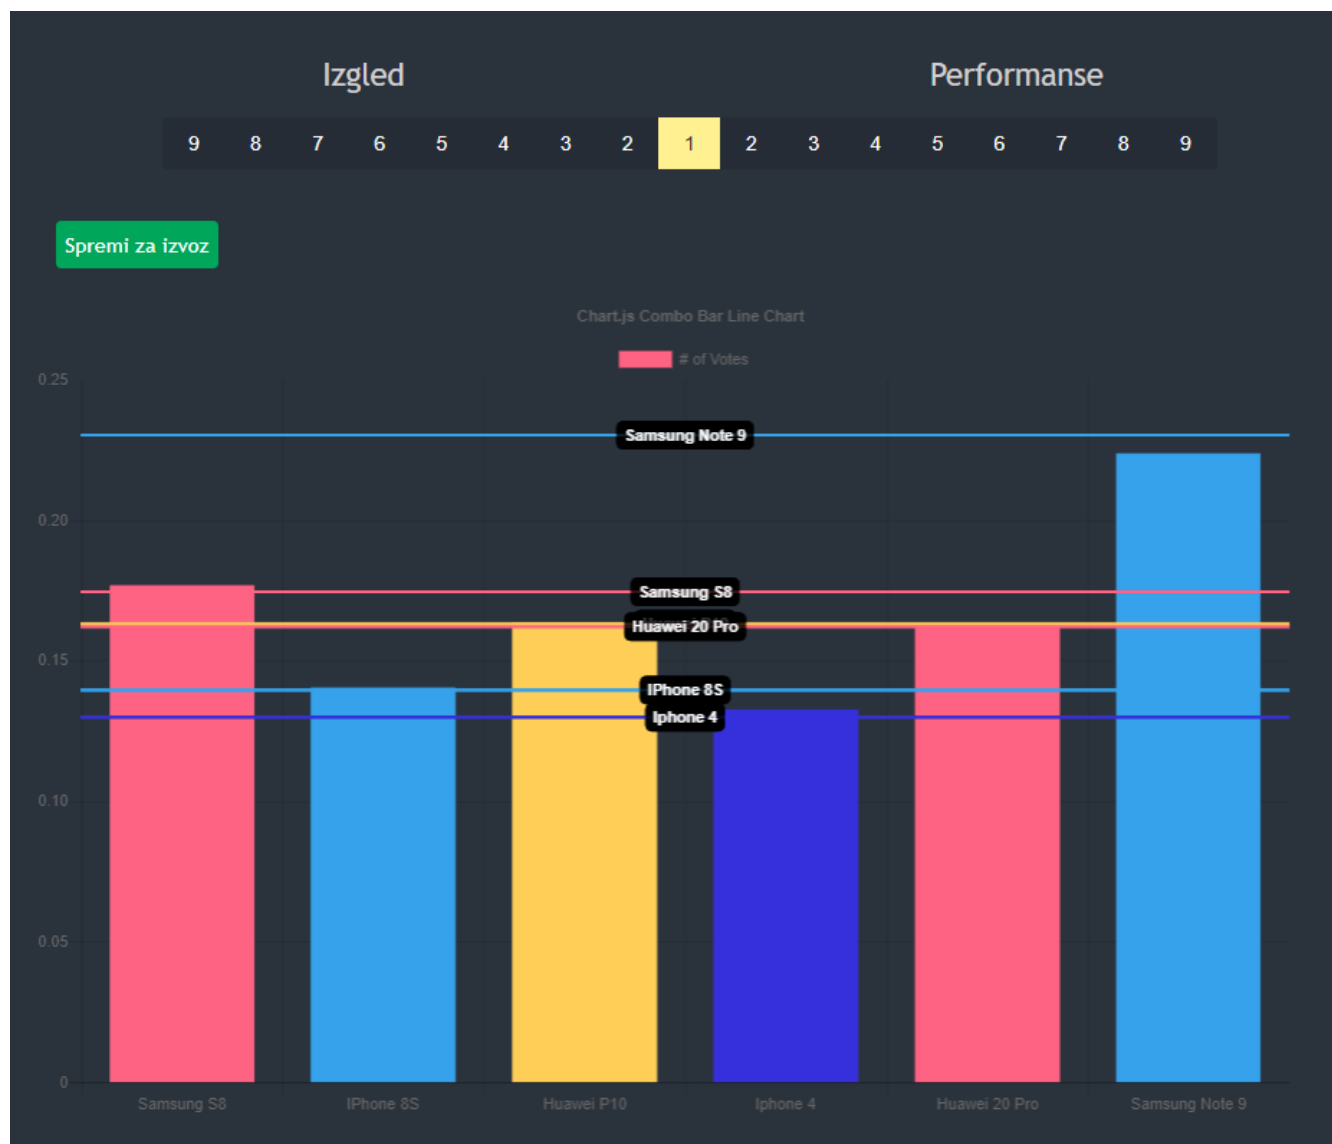
Slika 13 Uspoređivanje kriterija u parovima



Slika 14 Uspoređivanje alternativa u parovima, u odnosu na kriterij „Memorija“



Slika 15 Rezultat evaluacije



Slika 16 Analiza osjetljivosti konačnih rezultata na promjenu intenziteta važnosti kod pojedinih usporedba kriterija u paru

Dodaj novi projekt



Naziv izvještaja

Usporedba kriterija

Opis izvještaja

Definiraj legendu grafa (boje linija i stupaca)



Odustani

Spremi


Slika 17 Obrazac za spremanje dinamičkog grafa za izvještaj

Nakon evaluacije, slijede uobičajene analize osjetljivosti. Pri tome mislim na analizu performansi (engl. *Performance sensitivity*, Slika 18), dinamičku analizu (engl. *Dynamic sensitivity*, Slika 19) i *Head-to-head* analizu (engl. *Head-To-Head sensitivity*, Slika 20). Analiza performansi, kao i dinamička analiza, reagira na korisničke promjene vrijednosti kriterija. Primjerice, ukoliko povećamo vrijednost jednog kriterija, tada se vrijednosti njegovih podkriterija proporcionalno povećavaju, dok se vrijednosti kriterija s iste razine proporcionalno smanjuju. Također, konačna vrijednost svih alternativa se mijenjaju, ovisno o ovisnosti o tom kriteriju.


Kod svake korisničke interakcije kod navedenih dijagrama, slike istih je moguće spremiti pritiskom na gumb „Spremi za izvoz“. Tada se slike pohranjuju na poslužitelj te im je moguće pristupiti prilikom kreiranja izvještaja, što će biti objašnjeno u nastavku.

Slika 21 prikazuje obrazac za kreiranje izvještaja. Na obrascu su vidljive četiri sekcije, od kojih svaka predstavlja jednu analizu osjetljivosti. Svaka sekcija ima slike koje je korisnik spremao prilikom analiziranja. Korisnik ima mogućnost odabrati pojedine slike iz prikazanog skupa slika. Slike koje su odabrane biti će prikazane u izvještaju (Slika 21).


Nakon odabira sadržaja izvještaja, izvještaj se otvara u obliku *Word* dokumenta. Izvještaj sadrži naslovnu stranicu, naziv i opis projekta. Zatim je prikazan popis kriterija (Slika 22) i alternativa (Slika 23). U nastavku izvještaja, možemo vidjeti sve usporedbe kriterija koje je korisnik napravio tijekom evaluacije. Potom slijedi prikaz konačnih rezultata evaluacije (Slika 25), a zatim i analize osjetljivosti koje smo odabrali prilikom kreiranja izvještaja.



Slika 18 Analiza osjetljivosti performansi

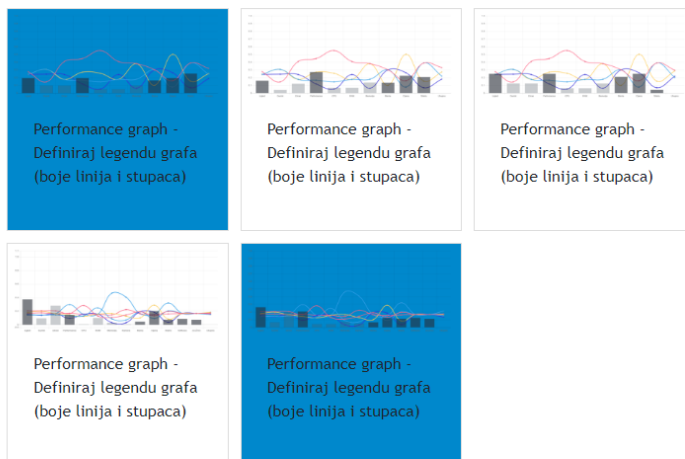


Slika 19 Dinamička analiza osjetljivosti

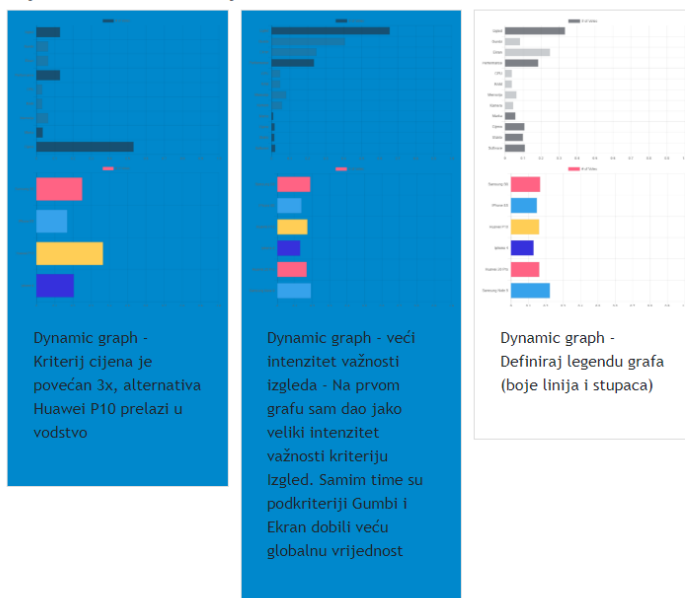


Slika 20 *Head-To-Head* analiza osjetljivosti

Performance sensitivity



Dynamic sensitivity



Head to head sensitivity



Slika 21 Obrazac za kreiranje izvještaja

Kriteriji

Naziv kriterija	Naziv roditelja	Globalna vrijednost (Lokalna vrijednost)	Konzistentnost
Izgled		(15,22%)	
Kriterij izgled svodi se na usporedbu alternativa prema podkriterijima Gumbi i Ekran			
Gumbi	Izgled	2,54% (16,67%)	
Ekran	Izgled	12,69% (83,33%)	
Performanse			0,0076
CPU	Performanse	6,23% (19,52%)	
RAM	Performanse	5,66% (17,74%)	
Memorija	Performanse	13,79% (43,21%)	
Kamera	Performanse	6,23% (19,52%)	
Marka		8,04% (8,04%)	
Cijena		12,53% (12,53%)	
Staklo		8,25% (8,25%)	
Software		15,79% (15,79%)	
Zvučnici		8,25% (8,25%)	

Slika 22 Prikaz kriterija u generiranom izvještaju

Alternative

Naziv alternative	Opis alternative
Samsung S8	
IPhone 8S	
Huawei P10	
IPhone 4	
Huawei 20 Pro	Huawei P20 i P20 Pro modeli spadaju među najnaprednije mobitele na tržištu.
Samsung Note 9	Samsung Galaxy Note 9 danas je službeno predstavljen i hrvatskim medijima u Zagrebu. Na hrvatskom tržištu Galaxy Note 9 bit će dostupan od 24. kolovoza 2018. u tri boje

Slika 23 Prikaz alternativa u generiranom izvještaju

	Samsung S8	IPhone 8S	Huawei P10	IPhone 4	Huawei 20 Pro	Samsung Note 9
Gumbi	Senzor naprijed, uobičajeno	Senzor otraga, naprijed nema gumba	Senzor otraga, jedan gumb naprijed	Staromodno		Senzor naprijed
Ekran	8*12	7.5 * 12 cm	7*11.5	6*10	7*12 cm	8*12.5
CPU	i7	i7	i7	i3	i7	i9
RAM	8 gb	4	8 gb	2	8	12
Memorija	32 gb (proširivo do 64 gb)	32gb	32 gb (proširivo do 128 gb)	8 gb	32 gb (proširivo do 128 gb)	64 gb (proširivo)
Kamera	12 mgpx	12 mgpx	12 mgpx	8 mgpx	Tri kamere, 12 mgpx	18 mgpx, Dual
Marka	Samsung	IPhone	Huawei	IPhone	Huawei	Samsung
Cijena	7200 kn	7800kn	6300 kn	2800 kn	7500 kn	9500 kn
Staklo	Gorilla glass Premium	Gorilla glass high quality premium				
Software	Android	IOS	Android	IOS	Android	Android
Zvučnici	Premium	Good	Good	Low quality	Good	Premium SS

Slika 24 Karakteristike alternativa prema kriterijima

Analiza rezultata

1.	Samsung Note 9 Samsung Galaxy Note 9 danas je službeno predstavljen i hrvatskim medijima u Zagrebu. Na hrvatskom tržištu Galaxy Note 9 bit će dostupan od 24. kolovoza 2018. u tri boje	23,05%
2.	Samsung S8	17,47%
3.	Huawei P10	16,33%
4.	Huawei 20 Pro Huawei P20 i P20 Pro modeli spadaju među najnaprednije mobitele na tržištu.	16,23%
5.	IPhone 8S	13,94%
6.	IPhone 4	12,98%

Slika 25 Prikaz konačnih rezultata - poredak alternativa prema globalnim vrijednostima

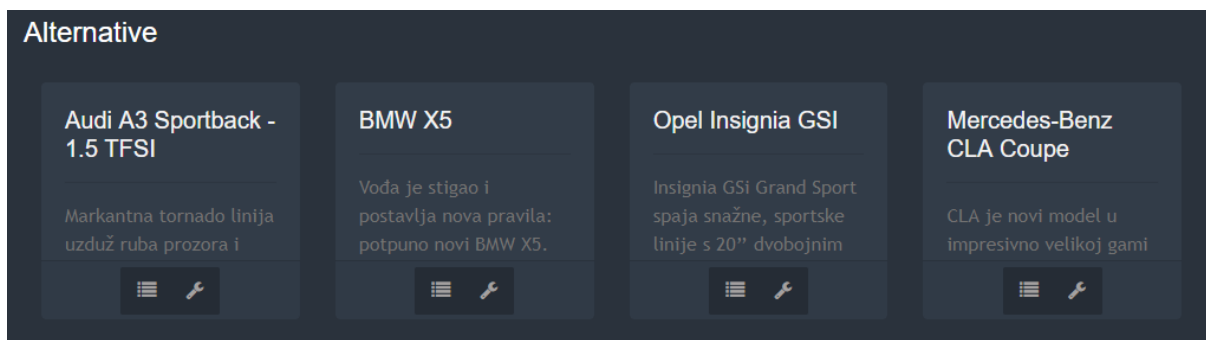
5. Demonstracija korištenja softver

5.1. Strukturiranje problema

U ovom poglavlju ću demonstrirati korištenje sustava pomoću primjera. U primjeru ću pokušati odrediti najoptimalnije rješenja za kupnju novog osobnog automobila [14].

Projekt smo kreirali upisivanjem naziva i opisa projekta, odnosno glavnog cilja projekta. Alternative odabiremo prema osobnim preferencijama, odnosno dodajemo sve one alternative koje možemo vidjeti kao konačni odabir. Da bismo započeli s projektom, moramo dodati alternative (Slika 26):

- Audi A3 Sportback – 1.5 TFSI
- BMW X5
- Opel Insignia GSI
- Mercedes-Benz CLA Coupe



Slika 26 Prikaz alternativa unutar aplikacije

Potom smo kreirali hijerarhijsku strukturu kriterija pomoću kojih ćemo izabrati najoptimalniju alternativu (Slika 27). Radi jednostavnosti ove demonstracije, nisam definirao još mnogo važnih kriterija, primjerice snaga automobila, CO_2 emisija, maksimalna brzina, tip motora, vrsta mjenjača, itd. Definirali smo četiri osnovna kriterija:

- Trošak
- Sigurnost
- Stil
- Kapacitet

Navedeni kriteriji dijele se na još nekoliko podkriterija, a kreirano hijerarhijsko stablo sastoji se od samo dvije razine. Kriterij Trošak, podijeljen je na kriterije Cijena kupovine, Potrošnja goriva, Trošak održavanja, Održiva vrijednost. Stil smo podijelili na kriterije Masu i Dizajn, dok kriterij Kapacitet dijelimo na kapacitet prtljažnika i broj putnika koji stane u automobil. Na slici su vidljive lokalne vrijednosti koje je aplikacija samostalno pridružila dodanim kriterijima i to ravnopravno svim kriterijima po razinama. Tako, na razini s četiri kriterija, svaki kriterij ima početni lokalni intenzitet važnosti 25 posto, dok na razini s ukupno dva kriterija, svaki kriterij ima početni lokalni intenzitet važnosti 50%.

Da bismo kasnije lakše vršili usporedbe alternativa u parovima, u odnosu na kriterije, dodati ćemo karakteristike alternativa prema tim kriterijima (Slika 28).

Kriteriji		
> Trošak	0%	+
> Cijena kupovine	25%	+ -
> Potrošnja goriva	25%	+ -
> Trošak održavanja	25%	+ -
> Održiva vrijednost	25%	+ -
> Sigurnost	0%	+ -
> Stil	0%	+
> Masa	50%	+ -
> Dizajn	50%	+ -
> Kapacitet	0%	+
> Prtljažnik	50%	+ -
> Putnici	50%	+ -

Slika 27 Hijerarhijska struktura kriterija

Karakteristike Audi A3 Sportback - 1.5 TFSI prema kriterijima ×

Sigurnost

Dobra

Cijena kupovine

168.000 kn

Potrošnja goriva

5 l/100km

Trošak održavanja

Vrlo dobar

Održiva vrijednost

Dobar

Masa

1305 kg

Dizajn

Vrlo dobar

Prtljažnik

Dovoljan

Putnici

5 (tjesno)

Odustani

Spremi promjene

Slika 28 Obrazac za dodavanje karakteristika alternative prema kriterijima



5.2. Uspoređivanje u parovima

Projekt smo započeli uobičajenim dodavanjem alternativa i kriterija, te uz jedan međukorak, misleći pri tome na definiranje stvarnih vrijednosti alternativa po kriterijima, možemo započeti s evaluacijom projekta. Prethodno smo upisali sve relevantne podatke alternativa, stoga će nam idući koraci biti lakši. Prvi korak je uspoređivanje kriterija u parovima, u odnosu na cilj ili nadkriterij, ovisno o tome pripada li kriterij najvišoj razini ili nekoj nižoj. Za svaku usporedbu dajemo intenzitet važnosti prema vlastitim preferencijama. Na slici 29 prikazani su odabrani intenziteti važnosti kriterija najviše razine prema mojim preferencijama. Isto činimo i za ostale razine hijerarhijskog stabla kriterija.

S ovako uspoređenim kriterijima, aplikacija nas izvještava da je konzistentnost prolazna, a iznosi 3.92%. S obzirom da je kriterij Trošak, po upisanom intenzitetu važnosti, važniji od sva tri ostala kriterija, možemo zaključiti da će ovaj kriterij imati najveću globalnu vrijednost. Zatim slijedi kriterij Sigurnost, te posljednje mjesto dijele kriteriji Stil i Kapacitet.

Nakon usporedbe kriterija svake razine, možemo započeti uspoređivanje alternativa. Prethodno unesene karakteristike svake alternative za definirane kriterije, postupak uspoređivanja alternativa nam čini puno jednostavniji (Slika 30). S obzirom da znamo cijenu svakog automobila, u našem primjeru vrlo lako možemo procijeniti intenzitete važnosti svake alternative. Nakon prvog kriterija, usporedbe alternativa radimo i u odnosu na ostale kriterije.

Početne usporedbe



Slika 29 Uspoređivanje kriterija najviše razine u odnosu na cilj

Cijena kupovine																
0.005339137505098179																
168.000 kn	Audi A3 Sportback - 1.5 TFSI								BMW X5							
	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8
168.000 kn	Audi A3 Sportback - 1.5 TFSI								Opel Insignia GSI							
	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8
168.000 kn	Audi A3 Sportback - 1.5 TFSI								Mercedes-Benz CLA Coupe							
	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8
568.000	BMW X5								Opel Insignia GSI							
	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8
568.000	BMW X5								Mercedes-Benz CLA Coupe							
	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8
365.000	Opel Insignia GSI								Mercedes-Benz CLA Coupe							
	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8

Slika 30 Uspoređivanje alternativa u odnosu na kriterij Cijena kupovine

5.3. Sinteza rezultata

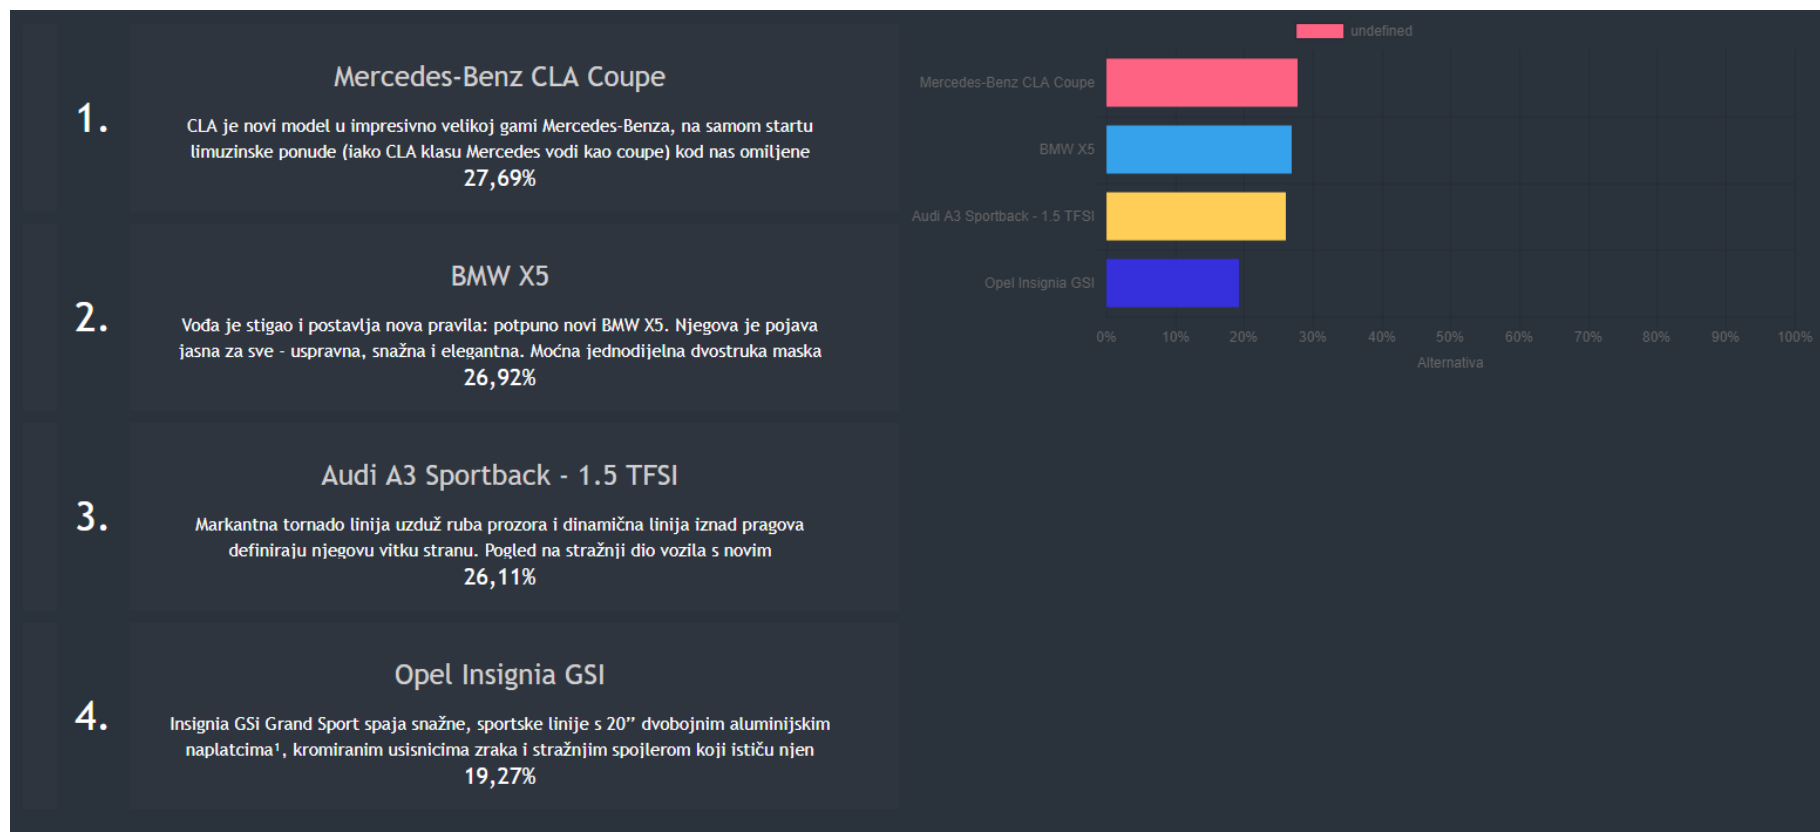
Nakon što smo napravili usporedbe svih alternativa i kriterija, aplikacija je izračunala sve globalne vrijednosti kriterija (Slika 31), te možemo krenuti na analizu rezultata (Slika 32). Aplikacija pokazuje sljedeći redoslijed automobila poredanih prema globalnom intenzitetu važnosti:

- Mercedes-Benz CLA Coupe (27,69%)
- BMW X5 (26,92%)
- Audi A3 Sportback – 1.5 TFSI (26,11%)
- Opel Insignia GSI (19,27%)

Konzistentnost kriterija najviše razine je 3.92%. S obzirom da je svaka konzistentnost ispod 10% prihvatljiva, ovaj rezultat je odličan. Razlike između prve tri alternative u konačnom poretku su manje od 1%, što znači da je možda čak samo jedna usporedba odlučila o optimalnom odabiru. U ovoj situaciji dobro je provesti analizu osjetljivosti, kako bismo sitnim promjenama vrijednosti kriterija mogli raspoznati sitne promjene konačnog poretku alternativa. Analiza osjetljivosti je proučavanje kako se nesigurnost izlaza matematičkog modela može podijeliti na različite izvore nesigurnosti [15].

Kriteriji				
>	Trošak		41,67%	+
>	Cijena kupovine	21,07%	50,55%	+ -
>	Potrošnja goriva	4,72%	11,32%	+ -
>	Trošak održavanja	10,38%	24,9%	+ -
>	Održiva vrijednost	5,51%	13,22%	+ -
>	Sigurnost	29,78%	29,78%	+ -
>	Stil		13,92%	+
>	Masa	6,96%	50%	+ -
>	Dizajn	6,96%	50%	+ -
>	Kapacitet		14,63%	+
>	Prtljažnik	2,44%	16,67%	+ -
>	Putnici	12,19%	83,33%	+ -

Slika 31 Pregled kriterija s izračunatim globalnim vrijednostima



Slika 32 Pregled konačnog poretka alternativa


5.4. Analiza osjetljivosti dobivenih rezultata

Analiza osjetljivosti je proces rekalkulacije ishoda odlučivanja s ciljem određivanja utjecaja pojedinih varijabla analize osjetljivosti na promjenu konačnog ishoda [16]. Postoje razne metode analiziranja osjetljivosti konačnih ishoda odlučivanja, no trenutno je u aplikaciji dostupno ukupno njih četiri, a to su:

- Analiza osjetljivosti konačnog ishoda na promjenu intenziteta važnosti pojedine usporedbe
- Analiza osjetljivosti performansi (*engl. Performance sensitivity analysis*)
- Dinamička analiza osjetljivosti (*engl. Dynamic sensitivity analysis*)
- Analiza osjetljivosti odnosa (*engl. Head-To-Head sensitivity analysis*)


5.4.1. Analiza osjetljivosti konačnog ishoda na promjenu intenziteta važnosti pojedine usporedbe

Izjednačavanjem intenziteta važnosti kriterija Trošak i Kapacitet, vidimo veliku promjenu u odnosu na početni ishod alternativa (Slika 33). Iako je alternativa Mercedes-Benz CLA Coupe imala prednost nad alternativom BMW X5, s razlikom od skoro 1%, nakon ove sitne promjene BMW X5 postaje vodeća alternativa, i to čak s razlikom od 2% nad alternativom Mercedes-Benz CLA Coupe.



Slika 33 Prikaz utjecaja promjene intenziteta važnosti usporedbe kriterija Trošak i Kapacitet

Također, promjena intenziteta važnosti kriterija Kapacitet u odnosu na kriterij Stil, uvelike utječe na konačni ishod (Slika 34). Ovom analizom osjetljivosti možemo zaključiti da je kriterij Kapacitet problematičan. Stoga je potrebno učiniti neke strukturne promjene ili promjene izračuna, kako bi sa sigurnošću mogli donijeti odluku.




Slika 34 Prikaz utjecaja promjene intenziteta važnosti usporedbe Kapaciteta i Stila

5.4.2. Analiza osjetljivosti performansi


Slijedi, možda i najkorisnija analiza osjetljivosti po pitanju prikaza dostupnih podataka, analiza osjetljivosti performansi. Odmah je vidljivo da navedena analiza, u odnosu na prethodnu pruža mnogo više informacija koje korisniku mogu biti od velike pomoć. Primjerice, u ovoj analizi korisnik može vidjeti lokalne vrijednosti alternativa. Na grafu (Slika 35) možemo prepoznati veliki utjecaj kriterija Kapacitet na alternativu BMW X5 (plava linija), no isto tako i veliki utjecaj kriterija Trošak, u odnosu na druge kriterije, na alternativa Audi A3.

S obzirom da sam prepoznao važnost kriterija Trošak za alternativu Audi A3, u sljedećem primjeru (Slika 36) sam ažurirao intenzitet važnosti kriterija Trošak. Početni intenzitet važnosti kriterija Trošak je bio 41,67%, a promijenio sam ga na 47.95%. Tom promjenom alternativa Audi A3 Sportback – 1.5 TFSI postala je vodeća s globalnom

vrijednošću 27,71%, a nakon nje slijedi alternativa Mercedes-Benz CLA Coupe s vrijednošću 27,41%.





Slika 35 Početni graf u analizi osjetljivosti performansi



Slika 36 Povećanje kriterija Trošak za 6%


5.4.3. Dinamička analiza osjetljivosti

Kao i kod analize osjetljivosti performansi, dinamička analiza osjetljivosti reagira na interakciju korisnika. Dok je po svojoj funkcionalnosti potpuno ista kao analiza osjetljivosti performansi, ona ne prikazuje lokalne intenzitete važnosti kriterija. No, dinamička analiza osjetljivosti pruža nam puno pregledniji grafički dizajn, što u nekim slučajevima može biti velika prednost (Slika 37).



Slika 37 Početni izgled dijagrama dinamičke analize osjetljivosti


Povećanjem intenziteta važnosti kriterija Kapacitet sa 14,36% na 20%, alternativa BMW X5 zauzima prvo mjesto u poretku alternativa poredanih prema njihovim globalnim vrijednostima (Slika 38).



Slika 38 Utjecaj promjene intenziteta važnosti kriterija Trošak na konačni ishod

5.4.4. Analiza osjetljivosti odnosa

Među navedenim, najjednostavnija analiza je analiza osjetljivosti odnosa (engl. *Head-To-Head sensitivity analysis*). Pruža nam vrlo pregledan uvid u odnos lokalnih vrijednosti dvaju odabranih kriterija (Slika 39).



Slika 39 Odnos alternativa BMW X5 i Mercedes-Benz CLA Coupe prema lokalnim intenzitetima važnosti

6. Zaključak

Iz dana u dan, sve više organizacija započinje informatizaciju poslovnih procesa s ciljem držanja konkurentnosti na tržištu. Ukoliko se želi izbjeći donošenje loših poslovnih odluka, informatizacija ne smije proteći bez uvođenja sustava za potporu pri odlučivanju. Kako se širi potreba za donošenjem ispravnih odluka, tako se širi i potreba za sustavima za potporu odlučivanju. Svaka pravovremena i ispravna odluka donosi uspjeh u poslovnom svijetu.

Kako se širi potreba za sustavima za potporu odlučivanju, tako bi se i razvitak istih morao unaprjeđivati. Ipak, još uvijek ne postoje sustavi koji pružaju sve važne funkcionalnosti za donošenje ispravnih i pravovremenih odluka. I dalje postoje sustavi koji nemaju podržano grupno odlučivanje, analizu osjetljivosti te opciju za definiranje stvarnih vrijednosti alternativa za dodane kriterije.

Kod navedenih sustava postoji veliki potencijal za proširenje funkcionalnosti analiziranja osjetljivosti, odnosno dodavanje novih opcija koje će unaprijediti krajnje donošenje odluka. Smatram da ovaj sustav ima dobre predispozicije za razvijanje u pravom smjeru, počevši od unaprjeđivanja prijave i registracije korisnika, unaprjeđenja analize osjetljivosti, pa sve do kompleksnog grupnog odlučivanja.

7. Popis literature

- [1] P. Sikavica, T. Hernaus, N. Begičević Ređep, i T. Hunjak, *Poslovno odlučivanje*. Školska knjiga Zagreb, 2014.
- [2] A. Cawsey, *The Essence of Artificial Intelligence*. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1997.
- [3] N. Begičević, „Višekriterijski modeli odlučivanja u strateškom planiranju uvođenja e-učenja“, University of Zagreb, Faculty of organization and informatics, 2008.
- [4] N. Begicevic, B. Divjak, i T. Hunjak, „AHP-based group decision making using keypads“, *International Journal of Economics and Business Research*, sv. 3, izd. 4, str. 443–458, sij. 2011.
- [5] T. L. Saaty, „Decision making with the analytic hierarchy process“, *Int. J. Services Sciences*, sv. 1, izd. 1, str. 83–98, 2008.
- [6] N. Kadoić, N. Begičević Ređep, i B. Divjak, „Structuring e-Learning Multi-Criteria Decision Making Problems“, u *Proceedings of 40th Jubilee International Convention, MIPRO 2017*, 2017, str. 811–817.
- [7] T. L. Saaty i L. G. Vargas, *Decision Making with the Analytic Network Process: Economic, Political, Social and Technological Applications with Benefits, Opportunities, Costs and Risks*. Springer; Softcover reprint of hardcover 1st ed. 2006 edition (December 28, 2009), 2006.
- [8] P. T. Harker i L. G. Vargas, „The Theory of Ratio Scale Estimation: Saaty’s Analytic Hierarchy Process“, *Management Science*, sv. 33, izd. 11, str. 1383–1403, stu. 1987.
- [9] T. L. Saaty, „The Analytic Network Process – Dependence and Feedback in Decision-Making: Theory and Validation Examples“, u *Business Applications and Computational Intelligence*, K. Voges i N. Pope, Ur. IGI Global, 2006, str. 360–388.
- [10] T. L. Saaty i M. Sodenkamp, „The Analytic Hierarchy and Analytic Network Measurement Processes: The Measurement of Intangibles“, sv. 1, izd. 1, str. 91–166, 2010.
- [11] W. W. Wu, „Choosing knowledge management strategies by using a combined ANP and DEMATEL approach“, *Expert Systems with Applications*, sv. 35, izd. 3, str. 828–835, 2008.
- [12] T. L. Saaty i L. T. Tran, „On the invalidity of fuzzifying numerical judgments in the Analytic Hierarchy Process“, *Mathematical and Computer Modelling*, 2007.

- [13] S. Moscovici i M. Zavalloni, „The group as a polarizer of attitudes“, *Journal of Personality and Social Psychology*, 1969.
- [14] Wikipedia, „Analytic hierarchy process – car example“, *Wikipedia*, 2017. [Na internetu]. Dostupno na: https://en.wikipedia.org/wiki/Analytic_hierarchy_process_-_car_example. [Pristupljeno: 13-ruj-2018].
- [15] A. Saltelli, „Sensitivity analysis for importance assessment“, u *Risk Analysis*, 2002.
- [16] D. J. Pannell, „Sensitivity analysis of normative economic models: Theoretical framework and practical strategies“, *Agricultural Economics*, 1997.

8. Popis slika

Slika 1 Odnos između rješavanja problema i odlučivanja (prilagođeno prema [1])	5
Slika 2 Primjer hijerarhijskog modela ([3]–[5])	8
Slika 3 Primjer konzistentnih elemenata	14
Slika 4 MVC arhitektura [15]	19
Slika 5 ERA model	23
Slika 6 Dijagram slučajeva korištenja	24
Slika 7 Obrasci za registraciju i prijavu korisnika	27
Slika 8 Početna stranica - pregled postojećih projekata	28
Slika 9 Obrazac za kreiranje novog projekta	29
Slika 10 Pregled osnovnih informacija projekta i alternativa	30
Slika 11 Pregled kriterija	31
Slika 12 Ažuriranje karakteristika alternativa prema kriterijima	32
Slika 13 Uspoređivanje kriterija u parovima	34
Slika 14 Uspoređivanje alternativa u parovima, u odnosu na kriterij „Memorija“	35
Slika 15 Rezultat evaluacije	36
Slika 16 Analiza osjetljivosti konačnih rezultata na promjenu intenziteta važnosti kod pojedinih usporedba kriterija u paru	37
Slika 17 Obrazac za spremanje dinamičkog grafa za izvještaj	38
Slika 18 Analiza osjetljivosti performansi	40
Slika 19 Dinamička analiza osjetljivosti	41
Slika 20 <i>Head-To-Head</i> analiza osjetljivosti	42
Slika 21 Obrazac za kreiranje izvještaja	43
Slika 22 Prikaz kriterija u generiranom izvještaju	44
Slika 23 Prikaz alternativa u generiranom izvještaju	44
Slika 24 Karakteristike alternativa prema kriterijima	45
Slika 25 Prikaz konačnih rezultata - poredak alternativa prema globalnim vrijednostima	45
Slika 26 Prikaz alternativa unutar aplikacije	46
Slika 27 Hijerarhijska struktura kriterija	48
Slika 28 Obrazac za dodavanje karakteristika alternative prema kriterijima	49
Slika 29 Uspoređivanje kriterija najviše razine u odnosu na cilj	51
Slika 30 Uspoređivanje alternativa u odnosu na kriterij Cijena kupovine	52
Slika 31 Pregled kriterija s izračunatim globalnim vrijednostima	54
Slika 32 Pregled konačnog poretka alternativa	55

Slika 33 Prikaz utjecaja promjene intenziteta važnosti usporedbe kriterija Trošak i Kapacitet	56
Slika 34 Prikaz utjecaja promjene intenziteta važnosti usporedbe Kapaciteta i Stila	57
Slika 35 Početni graf u analizi osjetljivosti performansi	58
Slika 36 Povećanje kriterija Trošak za 6%	58
Slika 37 Početni izgled dijagrama dinamičke analize osjetljivosti	59
Slika 38 Utjecaj promjene intenziteta važnosti kriterija Trošak na konačni ishod	60
Slika 39 Odnos alternativa BMW X5 i Mercede-Benz CLA Coupe prema lokalnim intenzitetima važnosti	60

9. Popis tablica

Tablica 1. Opći prikaz tablice odlučivanja [1]	6
Tabela 2 Saatyeva skala - temeljna skala apsolutnih brojeva [8], [9]	10
Tabela 3 Primjer matrice vrijednosti kriterija	13
Tabela 4 Indeksi vrijednosti [5]	15

10. Prilozi

U arhivi, priloženoj uz diplomski rad, nalazi se direktorij s projektom pod nazivom Odluka. Unutar navedenog direktorija, pojedine datoteke se mogu otvoriti samo pomoću aplikacije Visual Studio. Web aplikacija napisana je u C# programskom jeziku, a sva struktura aplikacije dostupna je na navedenom direktoriju.